

Centro de Enseñanza Técnica y Superior

Con reconocimiento de validez oficial de estudios del Gobierno del Estado de Baja California según Acuerdo de fecha 10 de octubre de 1983



Analizador universal de fallos de PLC para identificación de causa raíz de paro de máquina.

Tesis

para cubrir parcialmente los requisitos necesarios para obtener el grado de
Maestro en Ciencias de la Ingeniería

Presenta:

Manuel Antonio Ruiz Ochoa

Director:

Dr. Alejandro Guzman Ocegueda
Centro de Enseñanza Técnica y Superior (CETYS Universidad)

Tijuana, Baja California, México

2020

TITULO DE TESIS

Analizador universal de fallos de PLC para identificación de causa raíz de paro de máquina.

Presenta:

Manuel Antonio Ruiz Ochoa

y aprobada por el siguiente Comité

Dr. Alejandro Guzman Ocegueda
Director de tesis

Dr. Ricardo Martinez Soto
Coordinador del Posgrado en Ingeniería

Resumen de la tesis que presenta **Manuel Antonio Ruiz Ochoa** como requisito parcial para la obtención del grado de Maestro en Ciencias de la Ingeniería

**Analizador universal de fallos de PLC
para identificación de causa raíz de paro de máquina.**

Resumen aprobado por:

Dr. Alejandro Guzman Ocegueda
Director de tesis

El tiempo de diagnóstico de falla en equipo automatizado basado en PLC fue reducido aplicando inteligencia artificial con el entrenamiento de una red neuronal de 4 capas, 64 entradas y una base de datos de 42,114 registros de estado de máquina aprendidos de varias máquinas dentro de la empresa Schneider Electric, la efectividad en la detección correcta de la falla fue de 93.33%.

La reducción en tiempo de diagnóstico automatizado contra el diagnóstico humano de 26.05 minutos a 3.07 minutos fue sometido a un análisis estadístico de prueba t identificando una mejora de 22.98 minutos con un intervalo de 19.568 minutos a 26.401 minutos a un nivel de confianza de 95%.

Palabras clave: PLC, diagnóstico de fallas, anomalía, variables de entrada, variables de salida, estados de máquina, sensor, actuador, inteligencia artificial, aprendizaje de máquina, redes neuronales.

Abstract of the thesis presented **by Manuel Antonio Ruiz Ochoa** as a partial requirement to obtain the Master or Doctor of Science degree in Engineering with orientation in

**Universal PLC Failure Analyzer
for root cause identification of damaged machine**

Abstract approved by:

Dr. Alejandro Guzman Ocegueda
Thesis' Director

The fault diagnosis time in PLC-based automated equipment was reduced by applying artificial intelligence with the training of a 4-layer neural network, 64 inputs and a database of 42,114 machine status records learned from various machines within the company Schneider Electric, the effectiveness in the correct detection of the fault was 93.33%.

The reduction in automated diagnostic time against human diagnosis from 26.42 minutes to 3.07 minutes was subjected to a t-test statistical analysis identifying an improvement of 22.98 minutes with an interval of 19.568 minutes to 26.401 minutes at a 95% confidence level.

Keywords: PLC, diagnostics, fail, anomaly, input variable, output variable, sensor, actuator, machine states, artificial intelligence, learning machine, neural networks.

Dedicatoria

Dedico esta Tesis con mucho orgullo y cariño a mis hijas Jennifer y Estefanía, a mis hermanos y a mis padres quienes siempre me han apoyado incondicionalmente en todos mis retos personales y profesionales.

Agradecimientos

A CETYS por permitirme ser parte de este programa de estudio.

A Schneider-Electric y CONACYT por todo el apoyo brindado económica y laboralmente haciendo posible culminar este posgrado.

Al Dr. Alejandro Guzmán Ocegueda, por ser guía en la elaboración de mi proyecto de aplicación en las distintas asignaturas e impulsar un mejor nivel de proyección.

A los maestros, por haber proporcionado las asignaturas y bases necesarias, claves del éxito para el desarrollo, validación e implementación de esta aplicación.

Tabla de contenido

	Página
Resumen español.....	3
Resumen inglés.....	4
Dedicatorias.....	5
Agradecimientos.....	6
Lista de figuras.....	9
Lista de tablas.....	11
CAPÍTULO 1. INTRODUCCIÓN.....	12
CAPÍTULO 2. ANTECEDENTES.....	14
2.1 Métodos para identificar fallas en máquinas.....	15
2.2 Características deseables del sistema de diagnóstico de fallas.....	16
2.3 Transformación de las mediciones en un sistema de diagnóstico.....	18
2.4 Clasificación de los algoritmos para el diagnóstico.....	20
2.5 Sistemas basados en conocimiento histórico del proceso.....	21
2.6 Estado del Arte.....	26
2.7 Estadística de la línea base.....	29
CAPÍTULO 3. DEFINICIÓN DEL PROBLEMA DE INVESTIGACIÓN.....	36
3.1 Justificación.....	36
3.2 Pregunta de investigación.....	36
3.3 Hipótesis.....	37
3.4 Objetivos.....	37

CAPÍTULO 4. METODOLOGÍA.....	38
4.1 Desarrollo.....	38
4.2 Validación.....	53
4.3 Estadística.....	55
CAPÍTULO 5. RESULTADOS.....	59
5.1 Implementación.....	59
5.2 Validar confiabilidad.....	63
5.3 Prueba preliminar, verificar reducción de tiempo de diagnóstico.....	66
5.4 Medición de condiciones reales en campo.....	69
5.5 Prueba de hipótesis.....	70
CAPÍTULO 6. DISCUSION DE RESULTADOS.....	75
CAPÍTULO 7. CONCLUSIONES.....	76
Lista de referencias bibliográficas.....	77

Lista de figuras

Figura		Página
1	Muestra de diagnóstico manual (izquierdo) comparado con analizador universal de fallos de PLC (derecha).....	13
2	Representación general del proceso de diagnóstico.....	14
3	Transformaciones en un sistema de diagnóstico.....	18
4	Clasificación de algoritmos de diagnóstico.....	20
5	Configuración la red neuronal artificial del sistema de diagnóstico al agregarle los bloques especializados para este proyecto.....	23
6	Ejemplos de sistema sencillo para el diagnóstico.....	24
7	Ejemplos de sistema complejo para el diagnóstico cuando sólo solo son conocidos los estados de entrada y salida.....	25
8	Sistema SCADA.....	28
9	Grafica de tiempos de diagnóstico acumulado.....	29
10	Gráfica de Pareto, categorizado por tipo de falla.....	32
11	Tiempo promedio invertido para el diagnóstico utilizando el método humano categorizado por tipo de falla.....	33
12	Resultado en prototipo de estados de máquina en operación normal.	37
13	Resultado en prototipo de estados de máquina en operación con falla.	38
14	Ejemplo de un caso práctico de identificación de anomalía y diagnóstico de falla.....	40
15	Diagrama a bloques de Concepto esperado de software "Analizador Universal de fallos de PLC.....	41
16	Base de datos de los estados obtenidos con las matrices de medición X_o y C_o	43
17	Simplificación de la base de datos de los estados de máquina, obteniendo las matrices X_e y C_e	46
18	Matrices de características Y obtenidas de las varianzas σ y medias μ de las diferencias entre las salidas y entradas.....	48

19	Matrices de decisión D calculadas en base a umbrales de las características.....	49
20	Recolección de datos para la evaluación del diseño del sistema final.	51
21	Máquina Calibrador, de categoría operación simple.....	52
22	Máquina análoga, de categoría operación compleja.....	53
23	Resumen del proceso estadístico y comprobación de Hipótesis para las muestras poblacionales del sistema tradicional Humano H y el nuevo sistema Automatizado A.....	56
24	Analizador universal de fallos de PLC, pantalla principal en configuración para 16 entradas.....	57
25	Analizador universal de fallos de PLC, pantalla en proceso de aprendizaje-entrenamiento en máquina con 64 entradas.....	58
26	Analizador universal de fallos de PLC, pantalla en proceso de diagnóstico.....	58
27	Analizador universal de fallos de PLC, pantalla con diagnóstico concluido informando la causa de la falla en máquina de simple.....	59
28	Analizador universal de fallos de PLC, pantalla con diagnóstico concluido informando la causa de la falla en máquina compleja.....	59
29	Analizador universal de fallos de PLC, pantalla de configuración.....	60
30	Analizador universal de fallos de PLC, pantalla "Acerca de", Manuel Antonio Ruiz Ochoa.....	60
31	Gráfica de resultados de la diferencia en minutos, de la prueba de mejoramientos en tiempos de diagnóstico.....	65
32	Gráfica de resultados indicando el porcentaje de mejoramiento del Analizador Universal de fallos de PLC contra el método humano	66
33	Representación gráfica del análisis estadístico de porcentaje de reducción en tiempo de diagnóstico.....	70
34	Representación gráfica del análisis estadístico de pares de diferencias en tiempos de diagnóstico.....	71
35	Resultado de prueba t pareada aplicada a los datos en tiempos de diagnóstico automatizado contra humano.....	72

Lista de tablas

Tabla		Página
1	Revisión del estado del arte.....	27
2	Ejemplo de tabla 80-20 donde fueron tomados los valores de tiempo de diagnóstico.....	30
3	Tiempo de diagnóstico del programa prototipo para identificar sólo el estado de máquina con anomalía.	39
4	Tabla de sigmas representando sus correspondientes niveles de aceptación.	51
5	Tabla de aceptación en la detección de fallas conocidas, al desconectar cada señal de PLC, en máquina calibrador PA/1603.....	61
6	Tabla de aceptación en la detección de fallas conocidas, al desconectar cada señal de PLC, en máquina sorteador TP-004.....	62
7	Tabla de aceptación en la detección de falla conocida, al desconectar cada señal de PLC, en máquina análoga PE-791.....	63
8	Tabla de resultados de la prueba preliminar para verificar mejoramiento en tiempos de diagnóstico del método humano contra este nuevo sistema de diagnóstico automatizado.....	64
9	Tiempos de diagnóstico para recuperación de equipo caído de casos reales en producción en el periodo de un mes utilizando el programa Analizador Universal de Fallos de PLC.....	67
10	Tabla en pares de tiempos de diagnóstico, a la izquierda utilizando diagnóstico humano, a la derecha diagnóstico automatizado, para muestras dependientes, máquinas iguales con misma familia de falla.....	69
11	Criterio para aceptación o rechazo de hipótesis nula utilizando el estadístico Valor p de la prueba t pareada.....	72

Capítulo 1. Introducción

El proyecto de aplicación partió de una investigación documental para identificar las tecnologías disponibles para asistir el diagnóstico a través de análisis de entradas y salidas, seguido de una investigación de campo para construir un prototipo de software basado en aprendizaje de máquina utilizando los principios de redes neuronales y análisis de estados de máquina.

La investigación realizada en Schneider Electric identificó un tiempo perdido de producción en un mes de 3,679 minutos, representando \$15,415 dólares, tan sólo por el diagnóstico de fallas conocidas, estos números justifican el desarrollo de un sistema para el diagnóstico automatizado de fuentes de falla en equipo caído en menos tiempo.

Al realizar la investigación documental y de campo del estado del arte para sistemas de diagnóstico no fue encontrado sistemas de diagnóstico con enfoque correctivo.

Por lo tanto, fue desarrollo un programa de computadora para coleccionar la información de los valores de entradas y salidas de la máquina en operación, aprende su comportamiento en estado normal y lo compara contra el comportamiento también aprendido de la máquina caída, identificando la anomalía y la causa raíz a través del análisis de los estados posibles de máquina, combinado con la estimación de una red neuronal. Una vez desarrollado el prototipo de software, fue evaluada su confiabilidad al provocar fallas intensionales para todos los errores posibles de entrada y al aplicarlo sobre fallas reales de campo fue evaluada la rapidez en la detección de fallas al compararla con el método humano tradicional.

La figura 1 indica una sección de la interfaz de usuario del programa desarrollado. El sistema fue probado en la empresa Schneider Electric de la ciudad de Tijuana B.C.

El análisis estadístico para estimar la reducción de tiempo de diagnóstico identificó un mejoramiento del 86.44% en un rango del 83.82% al 89.06% a un intervalo de confianza del 95%. La prueba t pareada arrojó una reducción de 22.98 minutos con un intervalo de 19.568 minutos a 26.401 minutos a un nivel de confianza de 95%. La confiabilidad del programa para detectar correctamente la falla fue evaluada utilizando dos grupos de máquinas, el primero del tipo simples en donde los estados de máquina son secuenciales y el segundo grupo complejas, donde la máquina realiza diferentes operaciones en forma

simultánea. Para máquinas simples la confiabilidad resultó ser del 93.75% y en máquinas complejas del 94.28%.



Figura 1. Muestra de diagnóstico humano (arriba) comparado con método automatizado utilizando el analizador universal de fallos de PLC (abajo). Fuente: Elaboración propia.

Capítulo 2. Antecedentes

El término *falla* es definido como como una salida fuera de un rango aceptable de una variable asociada con un proceso. El evento de presentación de una falla es llamado *anomalía*. La figura 2 muestra un sistema de proceso controlado con sus fuentes de fallas. Son tres fuentes de fallas posibles: a) cambios en los valores de los parámetros en un modelo, b) cambios estructurales, c) mala funcionalidad de sensores y actuadores (Simon, 2011).

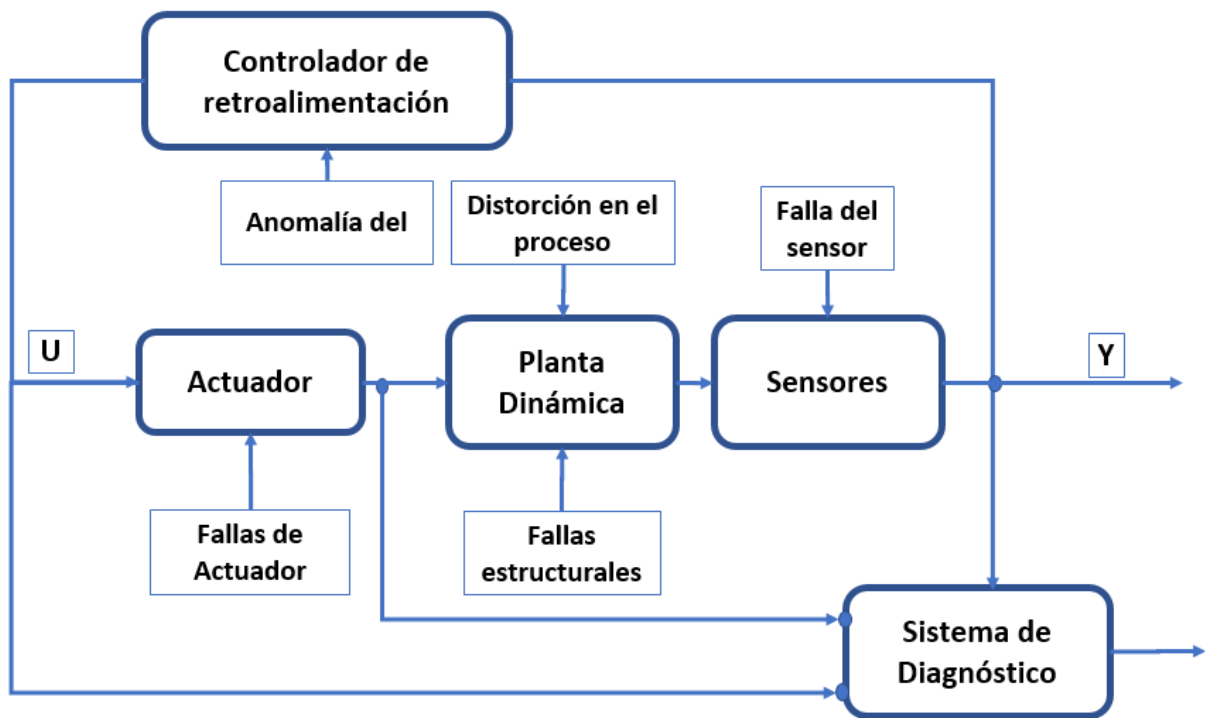


Figura 2. Representación general del proceso de diagnóstico. Fuente: adaptada de (Venkatasubramanian, 2003).

2.1 Métodos para la identificación de fallas en máquinas.

Las herramientas para lograr una óptima operación de la maquinaria son clasificadas en tres principales: a) preventivas, b) predictivas y c) correctivas. Las herramientas preventivas y predictivas están ampliamente desarrolladas, por ejemplo los sistemas SCADA monitorean de forma remota cada uno de los equipos, los sistemas ANDON son señalizaciones visuales en piso e indican el estado de la maquinaria, también existen algunas herramientas de carácter administrativo y de control tal como análisis FMEA, Mantenimiento Productivo Total TPM, estos sistemas pueden ser tan simples como capturas manuales en la computadora hasta adquisición automática de todos los parámetros de medición, también existen métodos donde el programa del PLC queda configurado para enviar las alertas necesarias al identificar una mala funcionalidad en alguno de sus estados. Estos sistemas predictivos o preventivos generan una base del conocimiento con el propósito de utilizarla cuando exista una condición irregular en el sistema proporcionando al usuario una recomendación para la detección temprana de la falla y evaluar el desempeño histórico del equipo (Socconini, 2019) .

El enfoque de este proyecto de tesis es el alcance correctivo, es decir, en la condición cuando el equipo automatizado está parado debido a algún daño en alguno de sus componentes y no ha sido configurado para indicar la falla de forma automática. Para este tipo de enfoque, el correctivo, no existe en el mercado un sistema electrónico o de cómputo para el diagnóstico de falla en PLC y en su ausencia la empresa depende de la habilidad del técnico.

2.2 Características deseables del sistema de diagnóstico de fallas.

Al comparar varios enfoques de diagnóstico, es usual identificar un grupo de características por poseer el sistema. Entonces los diferentes enfoques pueden ser evaluados contra un grupo de requerimientos estándar. Si bien estas características juntas no aparecen en ningún método de diagnóstico único, son métodos de referencia útiles y variados en términos de información a priori a proporcionar. En este contexto, deben ser comprendidos dos conceptos importantes, la *integridad* y la *resolución*, antes de proceder a definir las características de un buen clasificador de diagnóstico. Cada vez cuando ocurre una anomalía en el proceso, un clasificador de diagnóstico presentaría un conjunto de hipótesis o reglas para explicar la anomalía. La integridad de un clasificador de diagnóstico establece a la falla real sea un subconjunto del conjunto de fallas propuesto. La resolución de un clasificador de diagnóstico requeriría un conjunto de fallas minimizado. por lo tanto, existe una compensación entre integridad y resolución. La compensación está en la precisión de las predicciones. Estos dos conceptos son considerados cuando son comparados diferentes diseños de clasificadores (Venkatasubramanian, 2003). Las características de un sistema de falla son:

2.2.1 Detección rápida en el diagnóstico.

El sistema de diagnóstico debe responder rápidamente en la detección y diagnóstico de un proceso multifuncional. Sin embargo la respuesta rápida para diagnosticar fallas y al mismo tiempo el desempeño tolerable durante la operación normal son dos conflictos por resolver. Un sistema diseñado a detectar fallas de forma rápida será sensible a ruido y puede generar falsas alarmas.

2.2.2 Aislable.

La habilidad del sistema para distinguir entre diferentes tipos de falla.

2.2.3 Robustez

El sistema es robusto cuando es capaz de diagnosticar a pesar de la existencia de ruidos o incertidumbres.

2.2.4 Identificable

Uno de los mínimos requerimientos del sistema de diagnóstico es, poder identificar si el proceso está operando normal o anormalmente independientemente si la causa es conocida o desconocida.

2.2.5 Estimación de la clasificación del error

El sistema debe ser confiable en la estimación del error causante de la falla.

2.2.6 Adaptable

El proceso en la máquina puede cambiar, por lo tanto un sistema de diagnóstico ideal debería ser capaz de adaptarse a los cambios.

2.2.7 Facilidad de Explicación de la falla

El sistema de diagnóstico debe ser capaz de suministrar una explicación de cómo la falla fue originada y propagada para llegar a la actual situación.

2.2.8 Requerimientos de modelado

El sistema debe tener la capacidad de poder modelar el proceso actual.

2.2.9 Requerimientos computacionales y de almacenamiento

Las soluciones de rápido diagnóstico en tiempo real requieren algoritmos e implementaciones computacionales pero demandan altos niveles de almacenamientos.

2.2.10 Identificación de múltiples fallas

La habilidad para identificar múltiples fallas es un requerimiento importante pero muchas veces difícil. Es un problema difícil debido a la naturaleza de interacción entre las diferentes fallas y variables principalmente sobre procesos no lineales o no consistentes.

2.3 Transformación de las mediciones en un sistema de diagnóstico.

El proceso de decisión en el diagnóstico es una serie de transformaciones o mapeos de los procesos de mediciones. La figura 3 muestra las transformaciones durante este proceso.

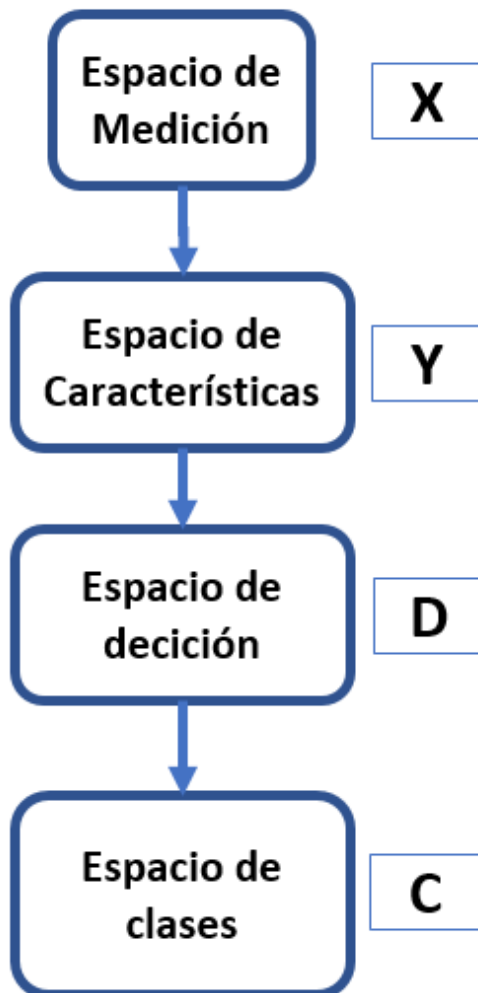


Figura 3. Transformaciones en un sistema de diagnóstico. Fuente: adaptada de (Venkatasubramanian, 2003).

2.3.1 El espacio de Medición.

El espacio de medición es la adquisición de los valores de las variables, por ejemplo, x_1, x_2, \dots, x_N en donde no existe conocimiento a-priori relacionado con esas mediciones. Son las entradas del sistema de diagnóstico, en la práctica son sensores o actuadores.

2.3.2 El espacio de características.

El espacio de características son los valores de puntos $y = (y_1, y_2, \dots, y_i)$ obtenidos como función de las mediciones a partir del conocimiento a-priori del problema. Aquí las mediciones son analizadas y combinadas con el cuidado de un conocimiento previo del proceso extrayendo las características útiles acerca del comportamiento para el diagnóstico.

2.3.3 El espacio decisión.

El mapeo desde el espacio de procesamiento hasta el espacio de decisión es usualmente designado para conocer una función objetivo. Esta información es lograda a través del uso de una función de discriminación o en algunos casos por un simple umbral, el espacio de decisión es un espacio de puntos $d = [d_1, d_2, \dots, d_k]$, donde k es el número de variables de decisión, obtenidas por las transformaciones del espacio de procesamiento.

2.3.4 El espacio de Clases.

El espacio de clases es un conjunto de valores enteros $c = [c_1, c_2, \dots, c_M]$, donde M es el número de tipos de fallas, indexando y categorizando la clase de fallas y especificando el patrón de medición normal donde pertenece. El espacio de clases es así entonces la interpretación final del diagnóstico hacia el usuario. La transformación del espacio de decisión al espacio de clases es realizada a través de funciones de umbrales, tablas de comparación o razonamiento simbólico lógico de acuerdo al caso.

2.4 Clasificación de los algoritmos para el diagnóstico.

Los métodos de diagnóstico para atender situaciones de carácter correctivo son clasificadas en dos principales categorías:

1. Basados en Modelos del Proceso
2. Basados en la Historia del Proceso.

A su vez cada uno es clasificado en cuantitativos y cualitativos.

La figura 4 muestra un diagrama de la clasificación de los algoritmos para el diagnóstico, aquí puede apreciarse el método a utilizar para este proyecto, el basado en *Historia de Proceso* con enfoque cuantitativo utilizando *Redes Neuronales Probabilísticas*. Estos métodos están en una etapa muy temprana y aún son un paradigma, y deben crearse nuevos algoritmos de acuerdo al caso particular. Debido a la gran extensión del problema de diagnóstico de fallas en procesos y las dificultades en su solución en tiempo real, han sido desarrollados a través de los años varios enfoques apoyados por la computadora (Lameda, 2015). Existen diversas investigaciones sobre el diagnóstico de fallas, van desde métodos analíticos a inteligencia artificial y enfoques estadísticos. Desde una perspectiva de modelado, algunos requieren modelos exactos del proceso, y otros modelos semicuantitativos o modelos cualitativos (Venkatasubramanian, 2003).

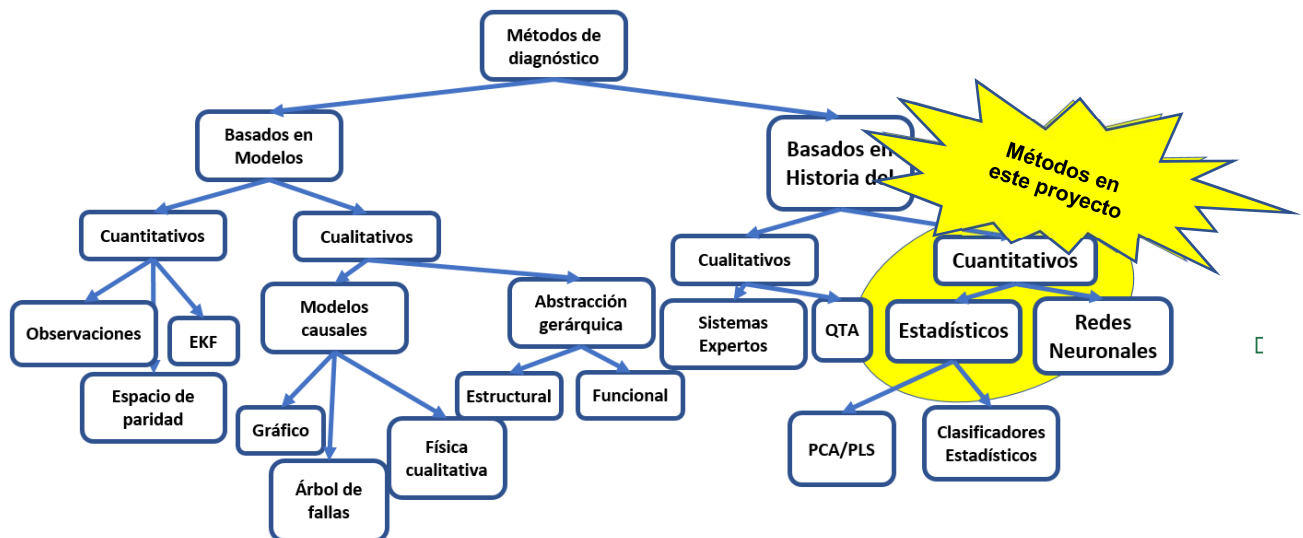


Figura 4. Clasificación de algoritmos de diagnóstico. Fuente adaptada de: (Lameda, 2015), (Venkatasubramanian, 2003),.

El método a utilizar es el basado en Historia del Proceso, por lo tanto las siguientes secciones no cubren los métodos basados en modelos.

2.5 Sistema basado en el conocimiento histórico del proceso.

En la industria es más común encontrar aplicaciones con enfoques basados en la historia del proceso. Esto porque son fáciles de implementar, requiriendo poco esfuerzo de modelado y conocimiento a priori y los modelos son usualmente estables. Un gran esfuerzo sería necesario para desarrollar modelos dinámicos especializados o universales dedicados a aplicaciones de detección de fallas.

Los enfoques basados en conocimiento tal como son implementados en sistemas de razonamiento automatizado incorporan heurísticas y razonamiento, donde es involucrada información incierta, en conflicto, y no cuantificable. Las tecnologías de *Inteligencia Artificial* están asociadas con enfoques basados en conocimiento, han sido adoptados para monitorización, control y diagnóstico e incluyen: a) sistemas expertos, b) lógica difusa, c) aprendizaje de máquinas d) reconocimiento de patrones y e) redes neuronales (Mira, 2008).

2.5.1 Inteligencia Artificial.

La Inteligencia Artificial (AI) es parte de un conjunto de disciplinas orientadas a crear una metodología eficiente para diagnosticar fallas. Los métodos basados en IA para el diagnóstico de fallas en su mayoría requieren también un conjunto de casos de síntomas conocidos (Juarez, 2008).

Las redes neuronales son una herramienta adaptada para detectar y diagnosticar fallas cuando están definidos los patrones con fallas de las variables del proceso, y cuando no es posible obtener un desacoplamiento del vector de fallas. Con respecto a la lógica difusa, es aplicada cuando existe la información suministrada por el experto en el proceso o equipos a diagnosticar. Los sistemas expertos aplican en aquellos sistemas donde existe una base de conocimiento sobre el dominio del proceso (Krisel, 2012) y cuando existen mecanismos de razonamiento para aplicar el conocimiento suministrado en las bases de datos para responder a las fallas.

2.5.2 Redes Neuronales Artificiales.

Las redes neuronales artificiales son un modelo computacional inspirado en el comportamiento observado en su homólogo biológico. Consiste en un conjunto de unidades, llamadas neuronas artificiales, conectadas entre sí para transmitirse señales. La información de entrada atraviesa la red neuronal (donde es sometida a diversas operaciones) produciendo unos valores de salida. Cada neurona está conectada con otras a través de unos enlaces. En estos enlaces el valor de salida de la neurona anterior es multiplicado por un valor de peso. Estos pesos en los enlaces pueden incrementar o inhibir el estado de activación de las neuronas adyacentes. Del mismo modo, a la salida de la neurona, puede existir una función limitadora o umbral, para modificar el valor del resultado o imponer un límite por ser sobrepasado antes de propagarse a otra neurona, esta función es conocida como función de activación (Matich, 2001).

Estos sistemas aprenden formándose a sí mismos, en lugar de ser programados de forma explícita, y sobresalen en áreas donde la detección de soluciones o características es difícil de expresar con la programación convencional. Para realizar este aprendizaje automático, es logrado al minimizar una función de pérdida al evaluar la red en su totalidad. Los valores de los pesos de las neuronas son actualizados en cada ciclo buscando reducir el valor de la función de pérdida. Este proceso es realizado mediante la propagación hacia atrás (Matich, 2001).

El objetivo de la red neuronal es resolver los problemas de la misma manera como lo hace el cerebro humano, aunque las redes neuronales son más abstractas. Las redes neuronales actuales suelen contener desde unos miles a unos pocos millones de unidades neuronales. Las redes neuronales son utilizadas para resolver una amplia variedad de tareas, como la visión por computadora y el reconocimiento de voz, difíciles de resolver usando una ordinaria programación basado en reglas. Históricamente, el uso de modelos de redes neuronales marcó un cambio de dirección a finales de los años ochenta de alto nivel, donde es caracterizado por los sistemas expertos como simples reglas de *si-entonces*, de bajo nivel de aprendizaje. (Zaknich).

El diagrama de una red neuronal con la adición de los procesos necesarios para este proyecto es mostrado en la figura 5.

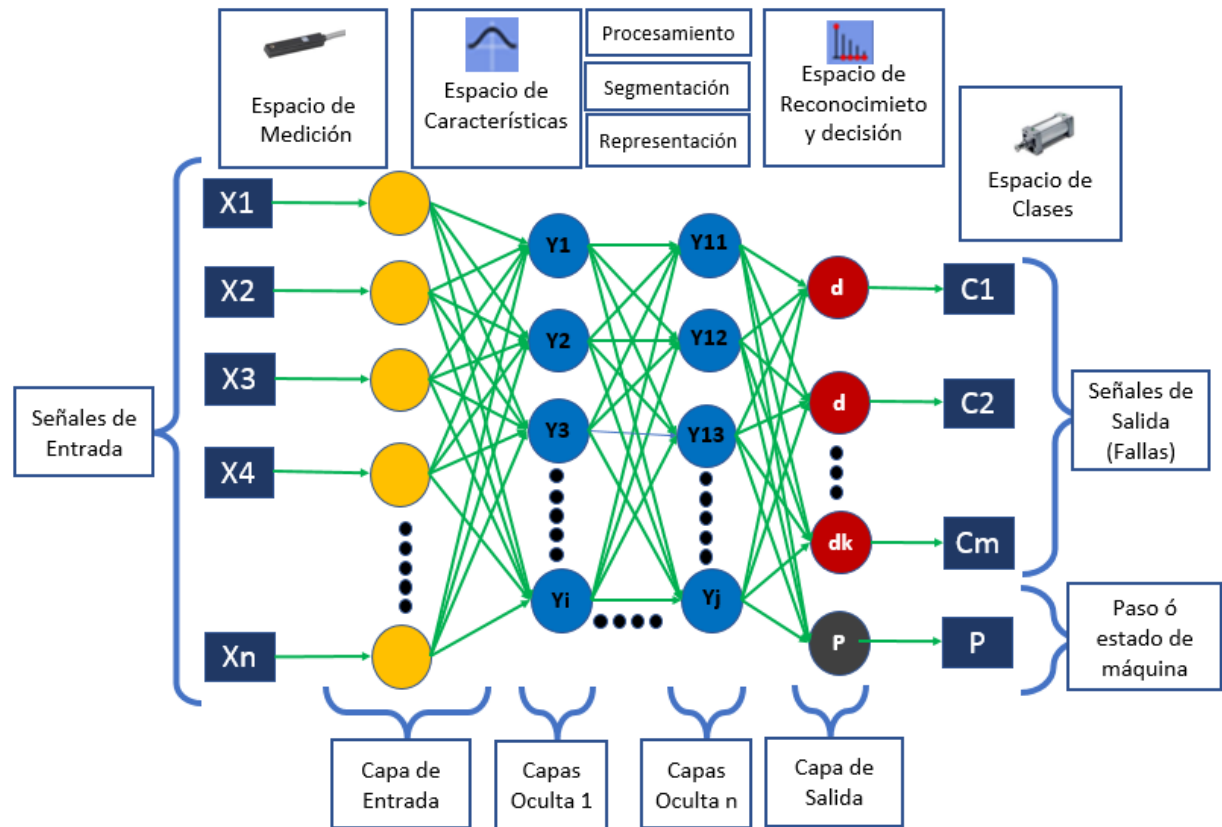


Figura 5. Configuración la red neuronal artificial del sistema de diagnóstico al agregarle los bloques especializados para este proyecto. Fuente: adaptada de (Hernández, 2014).

El entrenamiento de la red neuronal supervisada consiste en descubrir la relación entre las variables de salida con las de entrada cuando existe el conocimiento de los valores de salidas C_1, C_2, \dots, C_m forma dinámica. Una red neuronal realiza un proceso “hacia atrás”, como lo hace el ser humano al tratar de conocer las causas de los efectos. Una vez entrenada la red, puede identificar anomalías porque el sistema relaciona el estado de salida C_x con sus valores esperados en las entradas X_n .

2.5.3 Motivo de utilizar redes neuronales en este proyecto.

Un sistema simple donde la salida depende directamente sólo de una entrada como es mostrado en la figura 6, no habría dificultad para crear un sistema capaz de diagnosticar la fuente de una falla en la salida Cx pues infiere, la salida siempre sigue a su entrada y en el segundo ejemplo la salida también sigue a su entrada invertida, un método simple basado en reglas sería suficiente aquí, como un sistema experto.




Figura 6. Ejemplos de sistema sencillo para el diagnóstico. Fuente: Elaboración propia.

El sistema de multivariables de entrada y lógica intermedia, donde sólo son conocidos los estados de las entradas y salidas, como es mostrado en figura 7, sería muy extenso crear un sistema experto capaz de considerar todas las variantes de la lógica, sin embargo las redes neuronales resuelven el problema porque en base a su algoritmo son capaces de identificar los estados esperados de las variables de entrada para un valor de salida específico aunque sea desconocida la lógica del control, esto debido a la capacidad de ser entrenada. Cuando código del programa de un PLC es inaccesible para interpretar su lógica durante el diagnóstico de una falla una herramienta basada en red neuronal es una solución al problema.

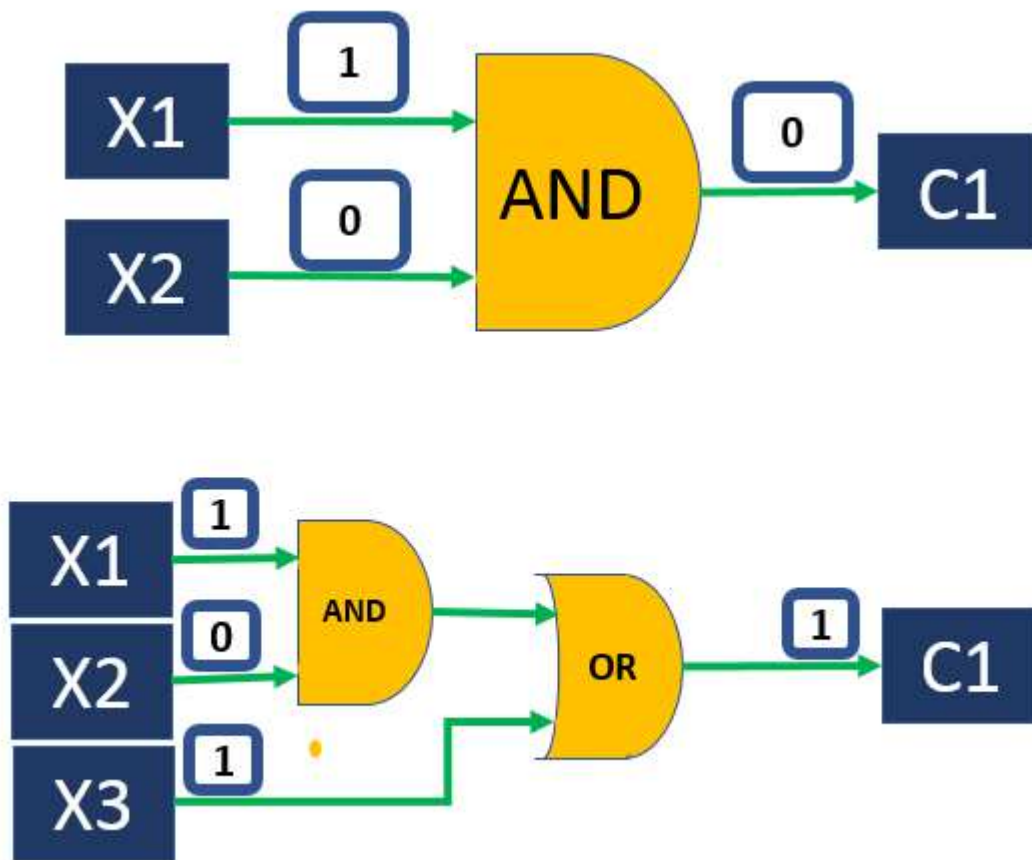


Figura 7. Ejemplos de sistema complejo para el diagnóstico cuando sólo solo son conocidos los estados de entrada y salida. Fuente: Elaboración propia.

2.6 Estado del Arte.

2.3.1 Investigación de aplicaciones comerciales.

Al realizar una investigación documental, técnica e industrial de lo más avanzado, para compararla con la propuesta de esta tesis, fue encontrado teoría respecto a los métodos de diagnóstico de fallas, sin embargo, no fue encontrado software práctico para asistir en forma automatizada al diagnóstico de equipo caído basado en PLC. Las aplicaciones encontradas están enfocadas al diagnóstico preventivo y predictivo, algunos ejemplos son mostrados en la tabla 1 y figura 8.

Fue realizado un análisis de fortalezas, oportunidades, debilidades y amenazas a partir del estado del arte, del sistema propuesto, “Analizador universal de fallos de PLC para identificación de causa raíz de paro de máquina”, y en base a su conceptualización, el sistema tiene las siguientes fortalezas, es decir características únicas no observadas en sistemas comerciales:

1. Enfocado a diagnóstico correctivo de máquina dañada.
 2. Entrenamiento basado en aprendizaje de estados de máquina en operación normal en vez de aprendizaje de síntomas.
 3. Suficiente el aprendizaje de estados posibles de máquina en operación normal contra el método tradicional de aprendizaje de una gran cantidad de posibles síntomas presentes y futuros.
 4. Análisis numérico comparativo de modo de operación normal y modo de operación en falla a través de la utilización de análisis de estados de máquina combinado con redes neuronales.
 5. Alcance universal, es decir, debido a la utilización de protocolo y direcciones estándar mod bus, capacidad de adaptarse a diversas marcas de fabricantes de PLC sin necesidad de configuración adicional.
 6. No requiere programación adicional en el PLC.
 7. No requiere librería de casos de fallas o algoritmos específicos por tipo de falla.
-

Tabla 1. Revisión del estado del arte. Fuente: adaptada de (Antúnez, 2016), (Lameda,2015), (Pascual, 2012), (Aquilino,2007).

Herramienta	Descripción	Aplicación en relación con el diagnóstico de fallas	¿Existe en SE?
SCADA	SCADA, (Supervisor control and data Acquisition), es un concepto empleado para realizar un software de computadora permitiendo controlar y supervisar procesos industriales a distancia.	Pronosticar de forma rápida el problema causante de un paro de máquina.	SI
ANDON	El Andon es un sistema utilizado para alertar de forma visual de problemas en un proceso de producción.	Da al operario o a la máquina automatizada la capacidad de detener la producción al encontrarse un defecto y de continuarla cuando es resuelto. Motivos comunes para el uso de la señal Andon pueden ser falta de material, defecto creado o encontrado, mal funcionamiento del equipo, fixturas o la aparición de un problema de seguridad.	SI
TPM	TPM (Total Productive Maintenance)	Prevenir fallas en el equipo a través de mantenimiento preventivo basado en histórico de fallas recurrentes.	SI
OEE Facility Advisor	OEE (Overall Equipment Effectiveness)	Permite la predicción en tiempo real de una posible mal función del equipo cuando la eficiencia cae a niveles bajos.	SI
Auto Spy	AutoSPy Registra, muestra y analiza los datos de una instalación controlada por PLCs.	Secuencia de registro de datos durante un determinado periodo. Análisis de las causas de interferencias. Optimización de procesos.	NO
FDD	FDD (Fault Detection and Diagnostics Software)	La tecnología FDD, Diagnóstico y Detección de Falla, reduce significativamente los costos y mejora la eficiencia de operación. Incorpora una librería de fallas y reglas hechas a la medida para predicen los problemas en los equipos y asesoran al personal para tomar acciones preventivas.	NO
Facility AnalytiX®	Software Predictivo de Fallas para la administración del edificio.	Facility AnalytiX® es un Sistema completo basado en la tecnología FDD. Facility AnalytiX incorpora opciones para configurar a medida fallas y reglas. También calcula la probabilidad de falla del equipo y entonces asesora al personal para tomar acciones preventivas mejorando así la seguridad, eficiencia y optimizando el ahorro de energía.	NO

SE: Schneider-Electric.

SCADA, (Supervisión, Control y Adquisición de Datos) es un concepto empleado para realizar un software para computadoras permitiendo controlar y supervisar procesos industriales a distancia. Facilita retroalimentación en tiempo real con los dispositivos de campo (sensores y actuadores), y controla el proceso automáticamente. Provee de toda la información generada en el proceso productivo (supervisión, control calidad, control de producción, almacenamiento de datos, etc.) y permite su gestión e intervención (Antúnez, 2016). El PLC es programado para enviar alarmas de fallas específicas de la máquina. La arquitectura SCADA es representada en la figura 8.

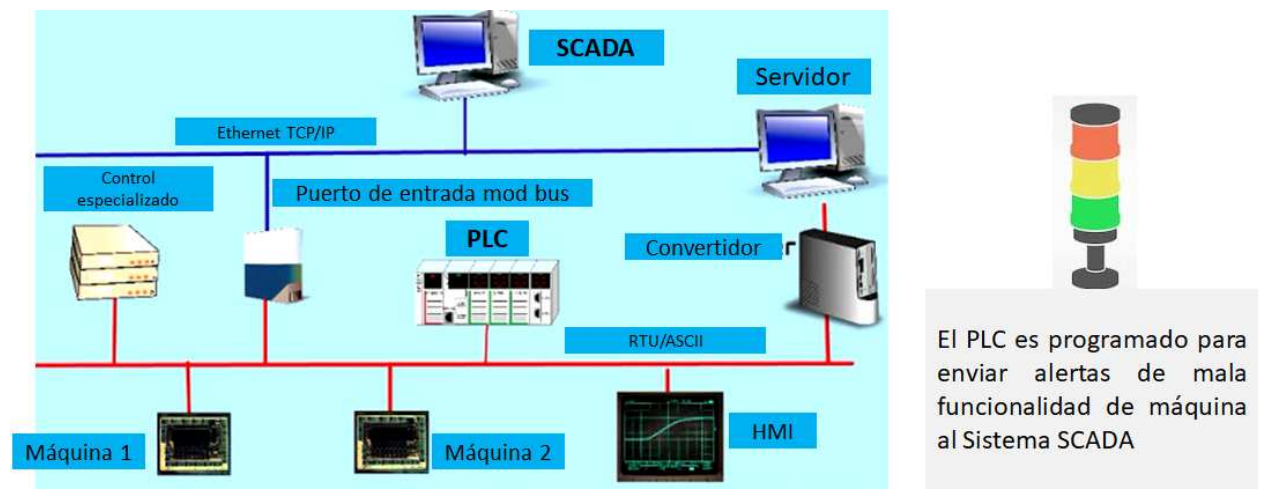


Figura 8. Sistema SCADA. Fuente: adaptada de (Antúnez, 2016), (Aquilino,2007).

2.7 Estadística de la línea base.

La línea base es los tiempos de diagnóstico, categorizado por cada tipo de falla en PLC.

Los siguientes apartados representan la estadística de la línea base sobre los tiempos perdidos actuales en maquinaria basada en PLC dentro de la planta de Schneider-Electric Tijuana.

2.7.1 Definición de la población.

Los registros de tiempos perdidos están disponibles en formatos capturados por los técnicos de mantenimiento, conocidos como 80-20 (Departamento de manufactura, 2020). La población representa 87 máquinas con 116 fallas en el mes analizado, debido a su tamaño, fue tomada la decisión de utilizar toda la población sin tener la necesidad de calcular una muestra.

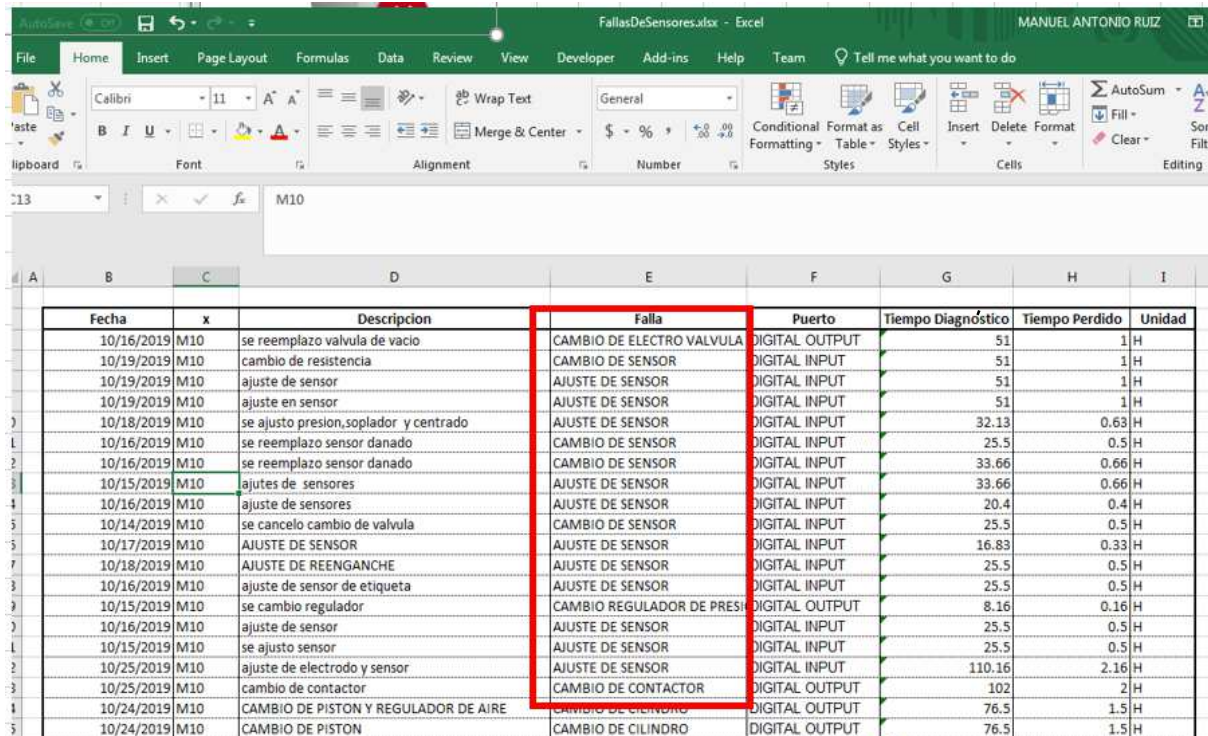
2.7.2 Recolección de datos.

Los registros actuales están en archivos de tablas excel, ahí es especificado el tiempo perdido por cada tipo de falla, es generado un archivo por semana, pero desafortunadamente las descripciones de las fallas no están estandarizadas, esto es, cada técnico le coloca el propio, entonces la tarea previa al análisis de los datos es preparar la información y clasificando los tipos de fallas, para esto fue utilizado el siguiente procedimiento.

2.7.3 Generación de archivo único para el análisis estadístico.

Clasificando cada tipo de falla, un archivo integrando fue obtenido con un nombre estándar para las fallas como muestra la tabla 2.

Tabla 2. Ejemplo de tabla donde fueron tomados los valores de tiempo de diagnóstico. Fuente: adaptada de registros SE 80-20 (Departamento de manufactura, 2020).



Fecha	x	Descripción	Falla	Puerto	Tiempo Diagnóstico	Tiempo Perdido	Unidad
10/16/2019	M10	se reemplazo valvula de vacio	CAMBIO DE ELECTRO VALVULA	DIGITAL OUTPUT	51		1 H
10/19/2019	M10	cambio de resistencia	CAMBIO DE SENSOR	DIGITAL INPUT	51		1 H
10/19/2019	M10	ajuste de sensor	AJUSTE DE SENSOR	DIGITAL INPUT	51		1 H
10/19/2019	M10	ajuste en sensor	AJUSTE DE SENSOR	DIGITAL INPUT	51		1 H
10/18/2019	M10	se ajusto presion,soplador y centrado	AJUSTE DE SENSOR	DIGITAL INPUT	32.13	0.63 H	
10/16/2019	M10	se reemplazo sensor danado	CAMBIO DE SENSOR	DIGITAL INPUT	25.5	0.5 H	
10/16/2019	M10	se reemplazo sensor danado	CAMBIO DE SENSOR	DIGITAL INPUT	33.66	0.66 H	
10/15/2019	M10	ajustes de sensores	AJUSTE DE SENSOR	DIGITAL INPUT	33.66	0.66 H	
10/16/2019	M10	ajuste de sensores	AJUSTE DE SENSOR	DIGITAL INPUT	20.4	0.4 H	
10/14/2019	M10	se cancelo cambio de valvula	CAMBIO DE SENSOR	DIGITAL INPUT	25.5	0.5 H	
10/17/2019	M10	AJUSTE DE SENSOR	AJUSTE DE SENSOR	DIGITAL INPUT	16.83	0.33 H	
10/18/2019	M10	AJUSTE DE REENGANCHE	AJUSTE DE SENSOR	DIGITAL INPUT	25.5	0.5 H	
10/16/2019	M10	ajuste de sensor de etiqueta	AJUSTE DE SENSOR	DIGITAL INPUT	25.5	0.5 H	
10/15/2019	M10	se cambio regulador	CAMBIO REGULADOR DE PRESI	DIGITAL OUTPUT	8.16	0.16 H	
10/16/2019	M10	ajuste de sensor	AJUSTE DE SENSOR	DIGITAL INPUT	25.5	0.5 H	
10/15/2019	M10	se ajusto sensor	AJUSTE DE SENSOR	DIGITAL INPUT	25.5	0.5 H	
10/25/2019	M10	ajuste de electrodo y sensor	AJUSTE DE SENSOR	DIGITAL INPUT	110.16	2.16 H	
10/25/2019	M10	cambio de contactor	CAMBIO DE CONTACTOR	DIGITAL OUTPUT	102	2 H	
10/24/2019	M10	CAMBIO DE PISTON Y REGULADOR DE AIRE	CAMBIO DE ELECTRO	DIGITAL OUTPUT	76.5	1.5 H	
10/24/2019	M10	CAMBIO DE PISTON	CAMBIO DE CILINDRO	DIGITAL OUTPUT	76.5	1.5 H	

2.7.4 Análisis de la línea base.

Al utilizar la información de la tabla anterior es obtenido la gráfica de figura 9 de tiempo acumulado por cada tipo de falla en el mes analizado por concepto de diagnóstico de fallas relacionadas con máquinas basadas en PLC, identificando un tiempo de 3,678 minutos, al multiplicarlo por el costo promedio por minuto perdido, estándar de la empresa, de \$4.19 dls. /minuto, arroja un costo total de \$15,415.01 dls. perdidos tan sólo por tiempo invertido en el diagnóstico de fallas utilizando el método tradicional humano.



Figura 9. Gráfica de tiempos de diagnóstico acumulado, categorizado por tipo de falla. Fuente: adaptada de Registros SE 80-20 (Departamento de manufactura, 2020).

La figura 10 representa la frecuencia por cada tipo de falla, es identificado los tres mayores contribuidores “Ajuste de Sensor”, “Cambio de Sensor” y “Ajuste de Cámara” representando el 81% de las fallas totales, los tres producen el mismo síntoma y entonces son unificados a un solo tipo llamado “Falla de Sensor”.




Figura 10. Grafica de frecuencia de fallas, categorizando tipo de falla. Fuente: adaptada de Registros SE 80-20 (Departamento de manufactura, 2020).

En la figura 11 es representado los tiempos de diagnóstico por cada tipo de falla calculándose la media para esos tres principales ofensores, 25.2 minutos.




Figura 11. Tiempo promedio invertido para el diagnóstico utilizando el método humano categorizado por tipo de falla. Fuente: adaptada de Registros SE 80-20 (Departamento de manufactura, 2020).

Capítulo 3. Definición del problema de investigación

Las fallas en equipo caído no pueden ser diagnosticadas de forma rápida y eficaz porque son dependientes de la habilidad humana (técnico), del nivel de complejidad y de la variedad de los sistemas, además no existe software de apoyo para esta actividad correctiva sobre equipo caído, esto fue explicado en detalle en el capítulo de antecedentes.

3.1 Justificación.

El estudio realizado en Schneider-Electric Tijuana indica, tan sólo por el diagnóstico de fallas conocidas, un tiempo perdido de producción promedio por mes de **3,679 minutos** (61.31 horas), esta nueva aplicación de diagnóstico automatizado reducirá el tiempo de diagnóstico.

Al realizar una investigación de ámbito documental, industrial y técnico, fue identificado la existencia de una gran variedad de herramientas para el pronóstico y prevención de fallas en maquinaria, pero no existen aplicaciones automatizadas para el diagnóstico desde el punto de vista correctivo cuando el equipo está descompuesto. Por lo tanto esta nueva herramienta viene a generar un gran impacto en el ahorro del negocio y ofrece una innovación en este campo.

3.2 Pregunta de investigación.

¿Cómo puede reducirse el tiempo para diagnosticar la falla de un sistema industrial basado en PLC?

3.3 Hipótesis.

Las siguientes hipótesis buscan ser comprobadas durante el desarrollo de esta investigación.

- **H₀** Una base de datos del estado de entradas con aprendizaje de máquina no reduce el tiempo de diagnóstico para fallas en sistemas industriales con PLC.
- **Ha** Una base de datos del estado de entradas con aprendizaje de máquina reduce el tiempo de diagnóstico para fallas en sistemas industriales con PLC.

La estructura de la prueba de hipótesis queda establecida al utilizar el término hipótesis nula, denotada con **H₀**. El rechazo de **H₀** conduce a la aceptación de la hipótesis alternativa **Ha**. (Walpole, 2012).

3.4 Objetivos.

3.4.1 Objetivo General

Reducir el tiempo de diagnóstico de fallas en máquinas caídas basada en PLC en más del 30%.

3.4.1 Objetivos Específicos

- Diseñar un nuevo software de diagnóstico automatizado para la detección de las fuentes de falla.
- Entrenar la red neuronal para detectar las entradas con falla con una efectividad mayor al 93.3%.

Capítulo 4. Metodología

La metodología partió de una investigación documental para identificar las tecnologías disponibles para asistir el diagnóstico a través de análisis de entradas y salidas, seguido de una investigación de campo para construir un prototipo de software basado en aprendizaje de máquina utilizando los principios de redes neuronales.

La metodología por seguir está basada en 4 etapas:

- Desarrollo.
 - Programa a nivel de prototipo.
 - Programa Final.
- Validación.
 - Pruebas de Confiabilidad.
- Estadística.
 - Recolección de datos.
 - Prueba de hipótesis.

4.1 Desarrollo.

La sección describe el concepto de la aplicación, el prototipo y las pruebas realizadas para comprobar la factibilidad.

4.1.1 Prototipo.

Utilizando la plataforma de desarrollo LabView, fue desarrollado un programa inicial sólo para validar la factibilidad, las secciones principales fueron:

1. Es establecida la comunicación inalámbrica mod bus TCP/IP.
2. Adquisición automática de cada uno de los cuatro tipos de variables a lo largo de la memoria del PLC, en tiempo real con máquina operando, dos módulos principales aquí:
 - a. Modo de aprendizaje y entrenamiento para máquina en operación normal.
 - b. Modo de aprendizaje y diagnóstico para máquina en operación con falla.
3. Son generados automáticamente, en cada uno de los dos casos, archivos conteniendo los estados de máquina correspondiente.

4. El archivo de aprendizaje en operación normal es estático porque es comparado contra los estados de los diversos equipos caídos.
5. El archivo de aprendizaje en operación de diagnóstico es dinámico porque es actualizado por cada máquina diagnosticada, o bien un archivo nuevo de diagnóstico es creado por cada entrenamiento sobre máquina caída.
6. Simplificación de los estados de máquina encontrados en ambos modos.
7. Comparación de estados aprendidos contra estados de diagnóstico, es el primer paso para lograr automatizar la interpretación del origen de la falla.
8. Fue aplicado el programa a una condición de máquina buena donde debería no haber cambio en el patrón de estados y así resultó como aparece en figura 12.
9. Fue aplicado el programa a una condición de máquina parada donde debería haber cambio en el patrón de estados y así resultó como aparece en figura 13.
10. Hasta este punto sólo fue identificado gráficamente el estado de máquina con anomalía, pero aún no la entrada específica con falla.

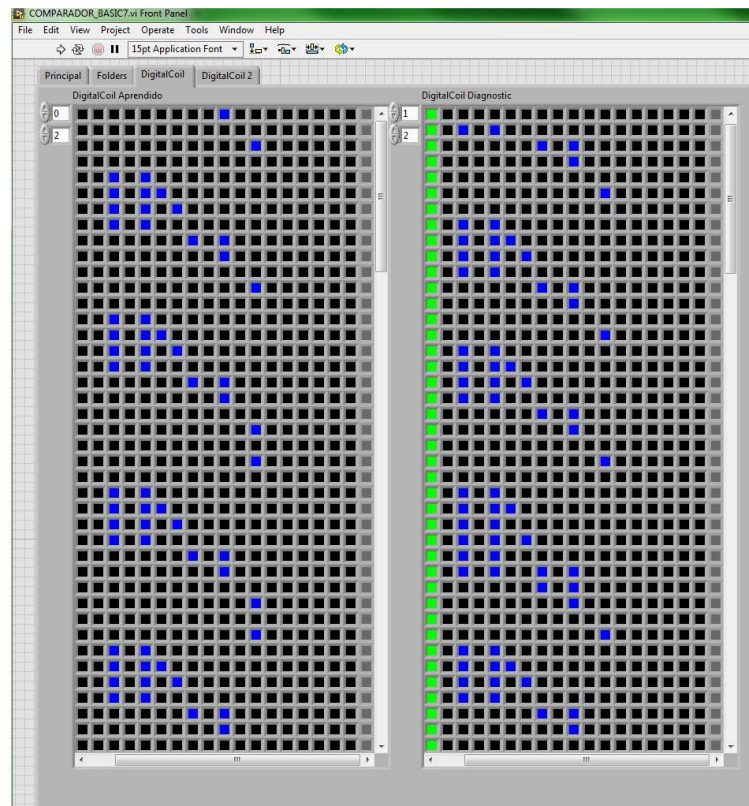


Figura 12. Resultado de estados de máquina en operación normal tipo sortador número TP-005. A la izquierda, patrón de estados de máquina, buena aprendidos, a la derecha estados de máquina diagnosticados de una máquina también buena. Fuente: Elaboración propia.

Al capturar mediciones para estados de máquina en operación con falla es obtenido el siguiente patrón de figura 13, donde fue observado gráficamente los estados con falla, siendo así posible establecer factibilidad del proyecto.

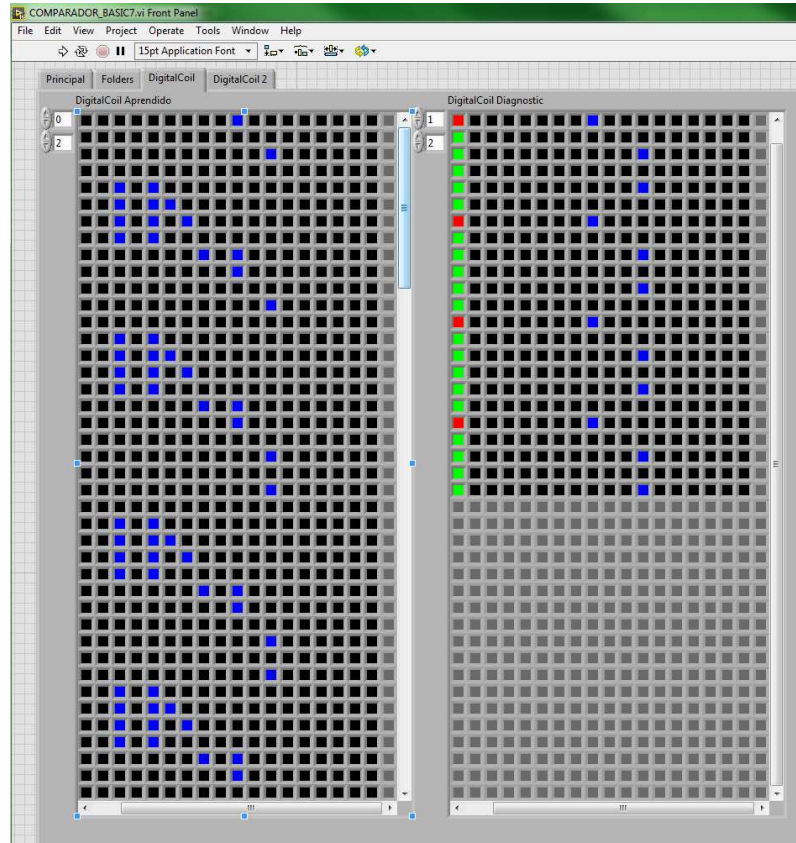


Figura 13. Resultado de estados de máquina en operación con falla tipo sorteador con identificador TP-005. A la izquierda, patrón de estados de máquina buena aprendidos, a la derecha estados de máquina diagnosticados de una máquina con falla, el punto rojo indica estados no correspondientes a las secuencias con anomalías. Fuente: Elaboración propia.

En esta prueba rápida y preliminar, con un nivel de desarrollo del programa muy básico, el tiempo para identificar la anomalía resultó como lo indica la tabla 3 para las fallas provocadas.

Tabla 3. Tiempo de diagnóstico del programa prototipo para identificar sólo el estado de máquina con anomalía. Fuente: Elaboración propia.

Tipo de Falla	Descripción	Detección de anomalía (minutos)	Detección correcta
Sensor de Entrada 3	Presencia de Interruptor	10.16	SI
Sensor de Entrada 7	Electrodo de carga extendido	10.16	SI
Sensor de Entrada 10	Actuador de reseteo extendido	9.16	SI
Sensor de Entrada 15	Presencia de Aire	8.16	SI

Media 9.41 minutos

Al comparar este valor con la media poblacional histórica de 25.2 minutos de figura 10, la reducción en tiempo fue:

$$25.2 \text{ minutos} - 9.41 \text{ minutos} = 15.79 \text{ minutos, correspondiente a } 62.65\%.$$

Esta reducción en tiempo es solamente para identificar el estado de máquina con la anomalía, pero aún faltaba identificar la entrada específica fuente de la falla, el algoritmo para identificar la falla específica sería más complejo aun, por tal razón fue planteada una reducción de máximo la mitad de este primer ensayo, es decir la estimación original fue obtener una reducción mayor al 30%.

4.1.2 Programa final.

Consiste en el desarrollo del sistema final, a diferencia del prototipo, indicará la fuente de la falla de forma gráfica pero también descriptiva.

4.1.2.1 Redes neuronales para identificación de causa raíz en fallo de máquina basada en PLC.

Considerar este ejemplo: en un PLC es creada una lógica, en donde la salida C1 con valor 1 activa un pistón cuando las entradas X tienen un valor de 1,0,1 (Sensores magnético, de proximidad y de cámara respectivamente) para un paso P como muestra en la figura 14. El sistema identifica la anomalía cuando en el paso conocido P el pistón C1 no es activado, entonces el sistema de diagnóstico debe tener la capacidad de identificar cuál o cuáles variables de entrada X no cumplen con la condición y de antemano el sistema desconoce la lógica del programa.

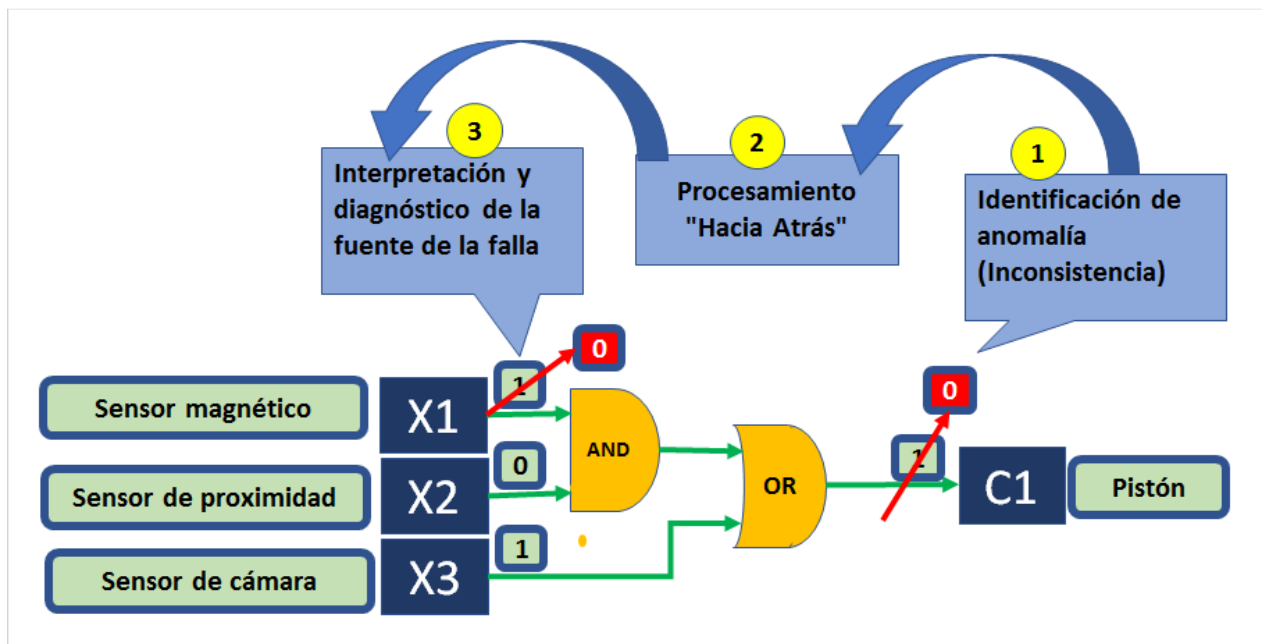


Figura 14. Ejemplo de un caso práctico de identificación de anomalía y diagnóstico de falla. Fuente: Elaboración propia.

Utilizando una tabla de verdad, existirían otros valores de entrada X para una salida de valor alto en C, pero la variable P detectaría la inconsistencia, así entonces el modelo debe cumplir también:

$$C = X \text{ AND } P$$

La teoría de redes neuronales establece definiciones y reglas básicas, pero la selección o creación de algoritmos depende de la aplicación en específico.

Son dos procesos principales donde participa la red neuronal en esta actividad de diagnóstico automático.

- Modo de aprendizaje y entrenamiento para máquina en operación normal.
- Modo de aprendizaje y diagnóstico para máquina en operación con falla.

El proceso de entrenamiento de la red es creado durante el aprendizaje en modo de operación normal y el diagnóstico es realizado durante un aprendizaje cuando la máquina está en operación con falla, ambos procesos de aprendizaje crean las matrices de características de comportamiento y al final una matriz de decisión. La figura 15 representa el diagrama a bloques del sistema final.

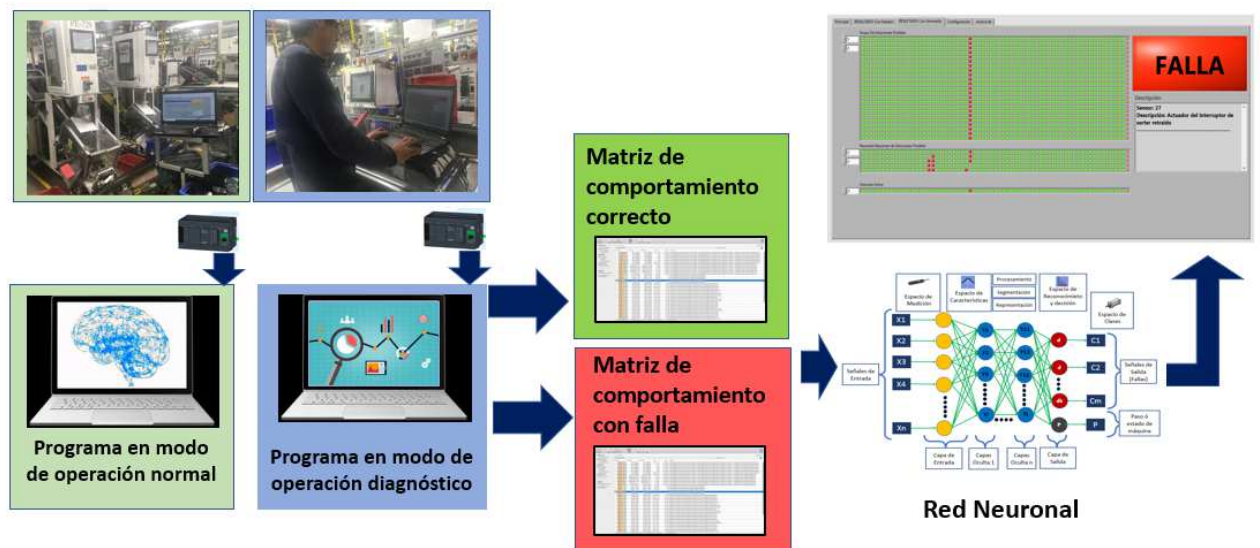


Figura 15. Diagrama a bloques del concepto de software “Analizador Universal de fallos de PLC para identificación de causa raíz de paro de máquina” incluyendo la etapa de redes neuronales. Fuente: Elaboración propia.

El principio básico de comparación establece un peso, representando la correspondencia de los estados de salida con los de entrada dentro de la red neuronal.

Para representar el algoritmo es utilizada la nomenclatura de letras mayúsculas y minúsculas, donde:

m: Cantidad de entradas digitales.

n: Cantidad de salidas digitales.

i: Cantidad de registros (renglones) leídos.

Espacios de la red entrenada de máquina en operación normal.

X: Arreglo de valores de las entradas, espacio de medición.

Y: Arreglos de valores de características, espacio de características.

D: Arreglo de valores calculados para la toma de decisión, espacio de decisión.

C: Arreglo de soluciones basado en la interpretación de la decisión, espacio de clases.

Espacios de la red entrenada de máquina en operación con falla.

x: Arreglo de valores de las entradas, espacio de medición.

y: Arreglos de valores de características, espacio de características.

d: Arreglo de valores calculados para la toma de decisión, espacio de decisión.

c: Arreglo de soluciones basado en la interpretación de la decisión, espacio de clases.

4.1.2.2 Espacio de medición.

Durante la operación de la máquina, el programa es comunicado al PLC utilizando el protocolo mod bus, lee el conjunto de registros de entradas y salidas digitales en tiempo real durante un tiempo t suficiente para aprender todos los estados posibles, incluyendo estados de aceptación de producto como de rechazo.

Consiste en registrar las variables de entrada X y el valor de salida C en tiempo real, pérdidas de valores entrantes podrían generar errores graves durante la interpretación de resultados, por ejemplo, si el cambio de una variable lo realiza cada 20ms, pero la velocidad de lectura es de 40ms, estaría perdiendo información de la relación entrada-salida.

Los dos tipos de registros de memoria son leídos del PLC por el programa de diagnóstico a través del protocolo mod bus TCP/IP durante un periodo de tiempo t y asigna esos valores a las entradas tipo X y salidas C , creándose así dos matrices:

- a) Matriz X_0 , de entradas originales de tamaño $m \times i$.
- b) Matriz C_0 , de salidas originales C de tamaño $n \times i$.

Ambos arreglos quedan grabados en una base de datos de archivos .csv del mismo nombre.

Adicional a estos valores, son creados datos de cabecera para cada captura:

- a) Índice i único, ambos, C y X deben corresponder el mismo valor en el mismo tiempo, es decir son arreglos X_{mi} , C_{ni} respectivamente.
- b) Tiempo de lectura en el instante i .

La figura número 16 representa esta operación.

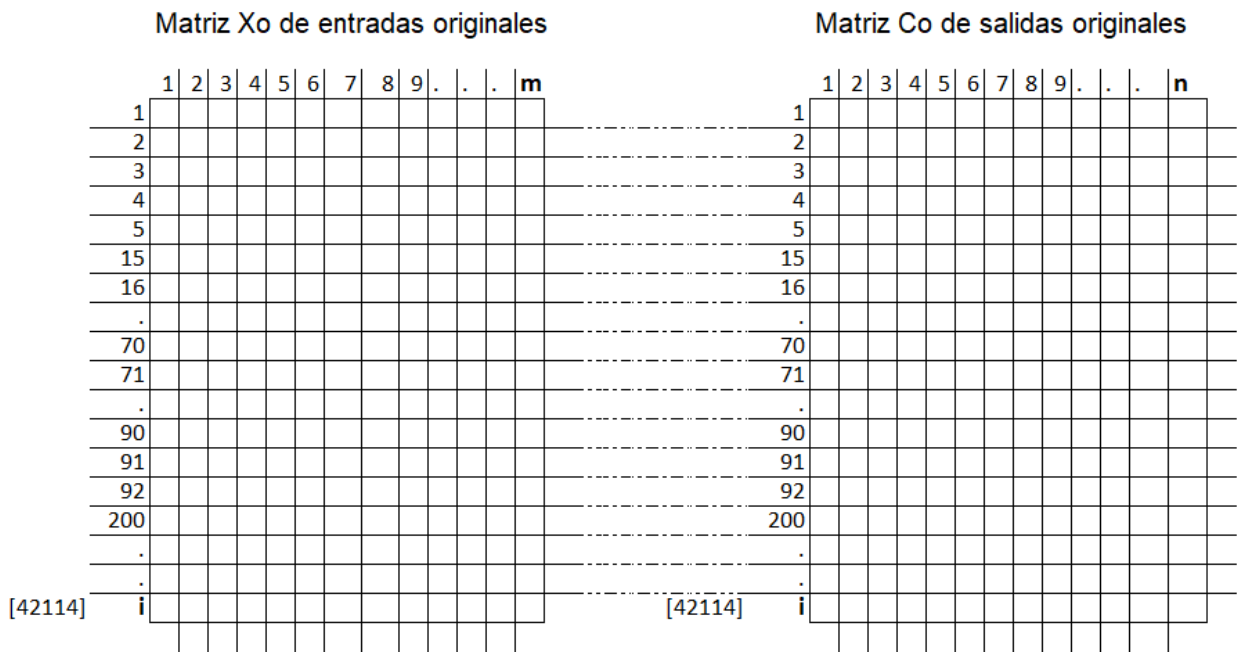


Figura 16. Base de datos de los estados obtenidos con las matrices de medición X_o y C_o . Fuente: Elaboración propia.

4.1.2.2 Espacio de características.

Aquí son creados los algoritmos para identificar las características del sistema y posteriormente son interpretados por la capa de decisión, son divididos en:

4.1.2.2.1 Procesamiento.

La función básica del procesamiento es de mejorar la calidad de la información para aumentar las posibilidades de éxito en los procesos posteriores. Debe validar una relación en tiempo real de pares salida-entrada, un desfase en la información capturada sería catastrófico para los datos posteriores, es logrado al verificar la existencia de los pares de identificadores tiempo creados en el espacio de medición anterior. Debe identificar variables innecesarias y dar mas contraste a las variables mas relevantes, es realizado a través de algoritmos para identificar actividad en las variables. Como el sistema leyó el conjunto de variables posibles de fábrica del PLC, de entradas digitales (arreglo X) y salidas digitales (arreglo Y) será mas eficiente aplicar a la red neuronal solo las variables relevantes, es decir sólo las variables dinámicas y omitir las estáticas, esto ayuda a ahorrar tiempo durante el diagnóstico. Es logrado al calcular las varianzas del conjunto de la población de las variables colectadas en la etapa de aprendizaje de máquina normal. Un valor de cero en la varianza indica no cambio en su valor en todo momento de operación de la máquina y entonces debe omitirse dicha variable en los cálculos subsecuentes. Son obtenidas entonces dos matrices:

- a) Matriz de entradas relevantes X.
- b) Matriz de salidas relevantes C.

Ambos quedan grabados en una base de datos de archivos .csv del mismo nombre.

4.1.2.2.2 Segmentación.

La segmentación consiste en partir o clasificar la información creando capas identificadoras de características propias y entonces pueden crearse valores cuantitativos representativos del comportamiento de la red, estas capas son divididas en pares de causa-efecto (entradas-salidas), es decir entradas digitales relevantes X y salidas digitales relevantes C para cada estado de máquina. Es simplificado el patrón eliminando los estados repetidos obteniendo un patrón de sólo los estados posibles en la máquina y obteniéndose entonces una matriz:

- a) Matriz de estados de entrada X_e de tamaño $m \times j$
- b) Matriz de estados de salida C_e de tamaño $n \times k$

j : La cantidad de renglones simplificados de las entradas.

k : La cantidad de renglones simplificados de las salidas.

Ambos quedan grabados en una base de datos de archivos .csv del mismo nombre.

Como resultado de las dos matrices anteriores, es creada una tercera y única matriz, representando los estados de salida dependientes a los estados de entrada.

- c) Matriz X_p de dependencia de estados entrada-salida de tamaño $m \times p$

Es generado una base de datos de archivo .csv del mismo nombre.

p : La cantidad de renglones de dependencia, llamado paso, identificador único del número de paso en la secuencia de operación del sistema.

La matriz resultante de este proceso es representada gráficamente en la figura 17

Matriz Xe de estados de entradas

	1	2	3	4	5	6	7	8	9	.	.	.	m
1													
3													
9													
12													
15													
30													
40													
50													
70													
72													
80													
88													
90													
101													
170													
200													
210													
600													
.													
.													
[42114]	j												

Matriz Ce de estados de salidas

	1	2	3	4	5	6	7	8	9	.	.	.	n
1	1												
2	15												
3	70												
4	90												
5	200												
6	230												
7	250												
8	600												
.	.												
.	.												
.	.												
p	k												

Matriz Xp de dependencia de estados entrada-salida

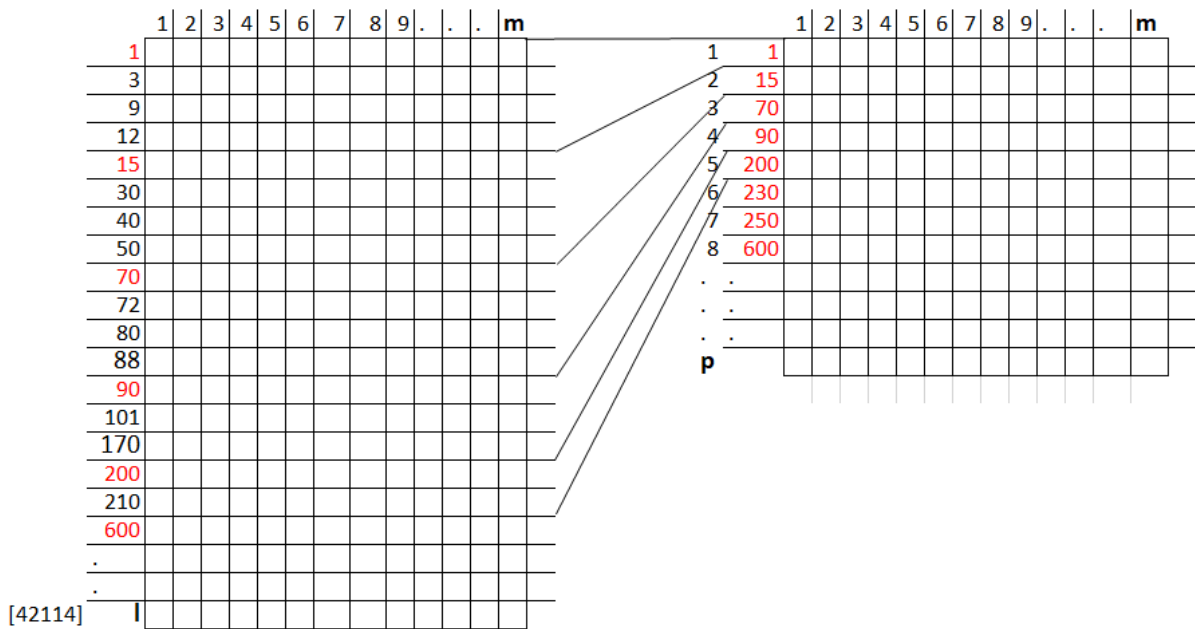


Figura 17. Simplificación de la base de datos de los estados de máquina, obteniendo las matrices Xe y Ce.
Fuente: Elaboración propia.

4.1.2.2.3 Ciclo de entrenamiento.

- a) Regresar al paso 4.1.2.2 para tomar una segunda muestra de medición.
- b) Comparar si los estados X_e y C_e de la muestra anterior estén contenidos en los estados X_e y C_e de la muestra actual.
- c) Si es correcto, continúa con la secuencia 4.1.2.2.4.
- d) En caso contrario regresar al paso a).

4.1.2.2.4 Representación y descripción.

La representación es solo una parte de la solución del problema para transformar los datos obtenidos durante la segmentación a una forma adecuada para ser posteriormente tratados, son resaltados los rasgos de interés a través de uno o varios parámetros y luego con la descripción son extraídos los rasgos de información cuantitativa de interés, fundamental para diferenciar una clase de otra, esto es logrado en el programa calculando las diferencias $C_e - X_e$, para cada estado de C_e le corresponde un grupo de líneas de estado C_e .

- a) Matriz Y de varianza de las diferencias $C_e - X_e$ específica para cada estado único de máquina.

Es generado una base de datos de archivo .csv del mismo nombre.

Es creada una matriz Y por cada dependencia de estados de la matriz X_p , es decir son creadas $Y_1, Y_2, Y_3 \dots Y_p$ matrices.

En cada matriz Y es descrito la varianza σ y la media μ , resultado de las operaciones sobre las diferencias de todas las combinaciones $C_e - X_e$, por lo tanto, esta matriz es de tamaño $(C_e \times X_e) \times 2$, columnas x renglones.

La matriz Y_p es entonces el descriptor fundamental del estado X_p

p : La cantidad de líneas de líneas de dependencia, llamado paso, identificador único del número de paso en la secuencia de operación del sistema. En la figura 18 es representada la tabla de características para cada estado de máquina.




Figura 18. Matrices de características Y obtenidas de las varianzas σ y medias μ de las diferencias entre las salidas y entradas. Fuente: Elaboración propia.

4.1.2.3 El espacio de decisión.

El mapeo desde el espacio de procesamiento hasta el espacio de decisión es usualmente designado para conocer una función objetivo. Esta información es lograda a través del uso de una función de discriminación o en algunos casos por un simple umbral, el espacio de decisión es un espacio de puntos $D = [D_1, D_2, D_3, \dots, D_p]$, donde p es el paso, identificador único del número de estado de máquina, obtenido en las transformaciones del espacio de procesamiento.

Este proceso consiste en asignar una etiqueta a un objeto D basándose en la información proporcionada por los descriptores Y.

1. Es identificado la dependencia causa-efecto del grupo de entradas $X_1, X_2, X_3, \dots, X_n$ con cada una de las salidas del grupo $C_1, C_2, C_3, \dots, C_m$.
 Si $Y=0$, hay dependencia porque varianza 0 significa la entrada siempre sigue a la salida.
 Si $Y=1$, no hay dependencia porque varianza 1 significa la entrada no sigue a la salida.

Si $0 < Y < 1$, la dependencia es parcial, por lo tanto, es definido un umbral de dependencia sesgado hacia el 0.

2. Es identificado la dependencia directa o inversa.

Si $\mu=0$, hay dependencia directa, porque las diferencias entrada-salida siempre son 0, es decir si la salida es 0, la entrada es 0, si la entrada es 1 la salida es 1.

Si $\mu=1$, hay dependencia inversa, porque el valor absoluto de las diferencias entrada-salida siempre son 1, es decir si la entrada es 0 la salida es 1 y viceversa.

Si $0 < \mu < 1$, la dependencia es parcial, por lo tanto, es definido un umbral de dependencia para cada sesgo izquierdo y derecho, existiendo la máxima incertidumbre cuando $\mu=0.5$.

3. De lo anterior son definidas las etiquetas de relación, utilizando las siguientes reglas de dependencia de entradas contra salidas.

- a. No dependencia: 0
- b. Dependencia directa: 1
- c. Dependencia inversa: -1

4. Es creada entonces la matriz de decisión a partir de las etiquetas encontradas en cada combinación.

- a. Matriz D de decisión, de tamaño $(C_e \times X_e) \times 1$, columnas x renglones para cada paso p, D1, D2, D3,...Dp.

El resultado de esta matriz D es explicado en figura 19.




Figura 19. Matrices de decisión D calculadas en base a umbrales de las características Y. Fuente: Elaboración propia.

4.1.2.4 El espacio de interpretación.

La interpretación es en sí el diagnóstico de la falla, es encontrado la fuente de la falla, es decir la entrada X cuyo valor no corresponda al valor esperado en la matriz D .

1. Es aplicado en modo de diagnóstico el programa, aprendiendo los valores X y C en operación con falla.
2. Es realizado las mismas operaciones explicadas para obtener las matrices de dependencia de estados entradas-salidas.
 - a. Matriz X_p de dependencia de estados entrada-salida de tamaño $m \times p$
3. Es obtenido el estado con anomalía en la secuencia en modo de falla, aquel cuyas entradas no corresponda a un estado X_e válido (conjunto de entradas no válidas).
4. Es encontrado el valor del estado p donde la anomalía es presente.
5. Al utilizar la matriz de decisión D , obtenida en el modo de aprendizaje de máquina en operación normal, son calculados los valores $X_1, X_2, X_3, \dots, X_m$ para la operación con falla correspondientes para el conjunto de salidas conocidas $C_1, C_2, C_3, \dots, C_n$ del paso p con anomalía.
6. La entrada o entradas X_i aprendidas en modo de diagnóstico del paso p con anomalía, no iguales a los valores calculados en el paso anterior, son la fuente de falla.

4.2 Validación.

Esta etapa evaluó la confiabilidad del diseño del sistema final, para asegurar una aceptación mayor o igual al 93.33%, este valor es derivado del estándar mínimo de la empresa en los procesos correspondiente a 1 Cpk, como es mostrado en la tabla 4.

Tabla 4. Tabla de sigmas representando sus correspondientes niveles de aceptación. Fuente: adaptada de (Pulido, 2010)

Nivel en Sigma	DPMO	Aceptación	Cpk
1	691462	30.90%	0.33
2	308770	69.10%	0.67
3	66811	93.33%	1.00
4	6210	99.40%	1.33
5	233	99.98%	1.67
6	3.44	99.99%	2.00

Esta etapa fue una evaluación previa antes de lanzar el programa al campo, fueron provocadas fallas conocidas de forma intencional para cada uno de los tipos de sensores de los tres tipos de máquinas posibles, los resultados son registrados en un formato, indicando el tiempo de diagnóstico y la aceptación, es decir si la falla fue identificada correctamente, este proceso es representado en la figura 27.

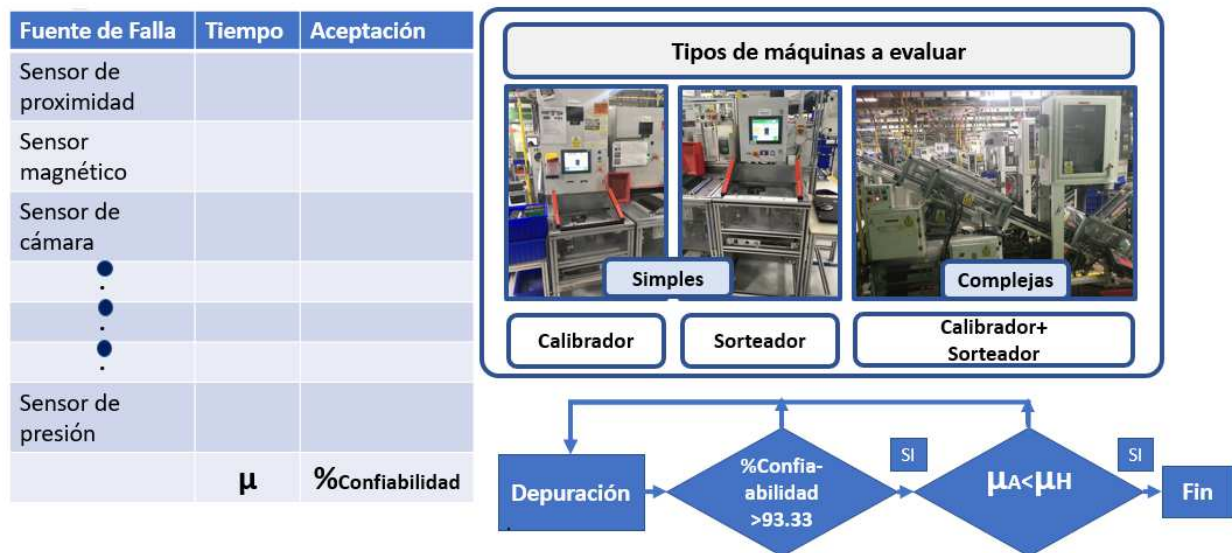


Figura 20. Recolección de datos para la evaluación del diseño del sistema final. Fuente: Elaboración propia.

Las pruebas fueron realizadas sobre dos grupos de máquinas, simples y complejas.

Máquinas simples: con múltiples operaciones simultáneas cada uno con estados de máquina propios, en particular dos tipos de máquinas, calibrador y sorteador. Es representada en figura 21.

Máquinas Complejas: Con operaciones ejecutadas en forma simultánea y cada operación con sus propios estados de máquina, en particular la máquina llamada análoga, combina en una misma estación automatizada las operaciones de calibrador, enfriador y sorteador. Es representada en figura 22.



Figura 21. Máquina Calibrador, de categoría operación simple. Fuente: Elaboración propia.



Figura 22. Máquina análoga, de categoría operación compleja. Fuente: Elaboración propia.

4.3 Estadística.

Una vez validado el programa y después de haber sido comprobada su confiabilidad en el diagnóstico de la fuente de falla, entonces fue lanzado el programa en condiciones reales de fallas de máquinas en el campo.

4.3.1 Hipótesis estadística.

Sea:

μ_A : Media poblacional de método de diagnóstico automatizado con esta nueva aplicación para los tiempos de diagnóstico.

μ_H : Media poblacional de método de diagnóstico humano tradicional.

Entonces la hipótesis estadística fue planteada de la siguiente manera:

$$H_0: \mu_A \geq \mu_H$$

$$H_a: \mu_A < \mu_H$$

4.3.2 Recolección de datos.

Para el rechazo de la hipótesis nula a través de método de *Prueba t*, fueron colectaron los siguientes datos:

1. 94 datos de tiempos de diagnóstico de “Fallas de Sensor” correspondientes a la población de un mes para caso actual donde el diagnóstico es humano, recolectados de los datos históricos en formatos 80-20 de la fábrica, obteniéndose una media poblacional de $\mu_H=25.2$ minutos.
2. Aplicando el programa desarrollado, Analizador Universal de Fallos de PLC, fueron diagnosticadas la fuente de la falla del equipo caído a 36 casos de “Fallas de Sensor” durante un mes.
3. Para propósitos de utilizar el estadístico de prueba t pareada, fueron buscados en el histórico de archivos 80-20 de la fábrica, 36 fallas de misma familia y tipo de equipo para cada una de las diagnosticadas en el mes de febrero-2020

4.3.3 Prueba de hipótesis.

Al comparar las medias poblacionales de los dos grupos, diagnóstico humano contra diagnóstico automatizado (μ_A , μ_H), el modelo ideal para comprobación de hipótesis es el modelo estadístico prueba *t* *pareada*.

Para esta población normal, el estadístico *t* es:

$$t = \frac{\bar{d}}{sd/\sqrt{n}} \text{ (Walpole, 2012)}$$

\bar{d} : Media de las diferencias de las dos muestras.

sd: Desviación estándar de las diferencias de las dos muestras.

Z: Puntuación Z para el nivel de confianza.

α : Error de la muestra.

n : Tamaño de la muestra.

Como resultado, el procedimiento de prueba consiste en no rechazar **H₀** cuando

$$-z\alpha/2 < z < z\alpha/2 \text{ (Walpole, 2012)}$$

El proceso estadístico y de prueba de la hipótesis es resumido en la siguiente figura 23.

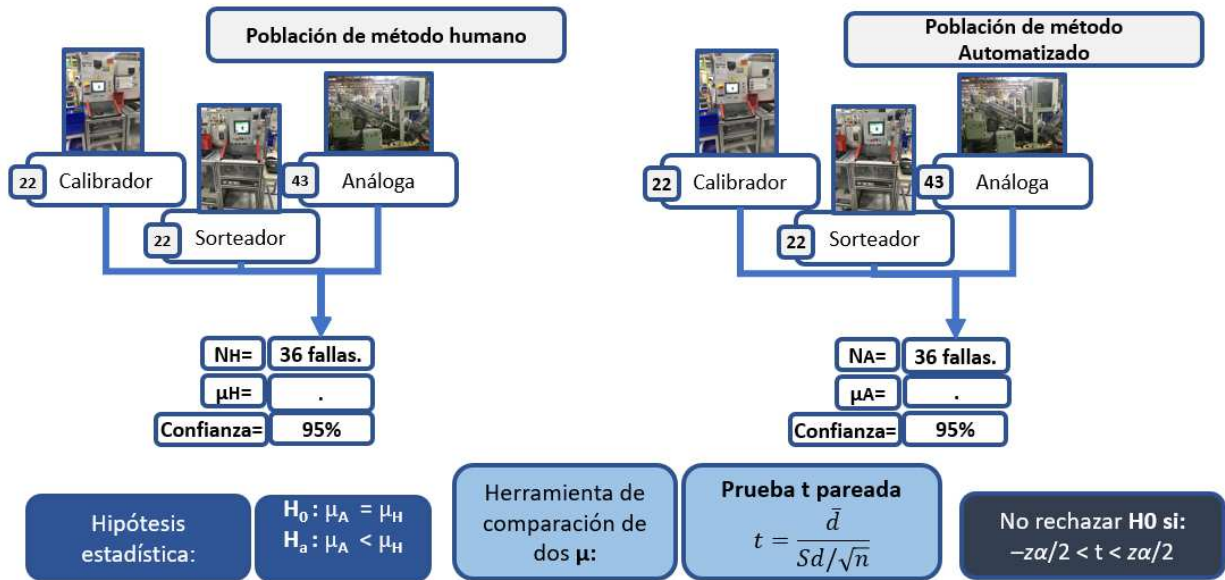


Figura 23. Resumen del proceso estadístico y comprobación de Hipótesis para las muestras poblacionales del sistema tradicional humano H y el nuevo sistema Automatizado A.

Capítulo 5. Resultados

5.1 Implementación.

Las figuras siguientes presentan algunas pantallas del programa implementado.

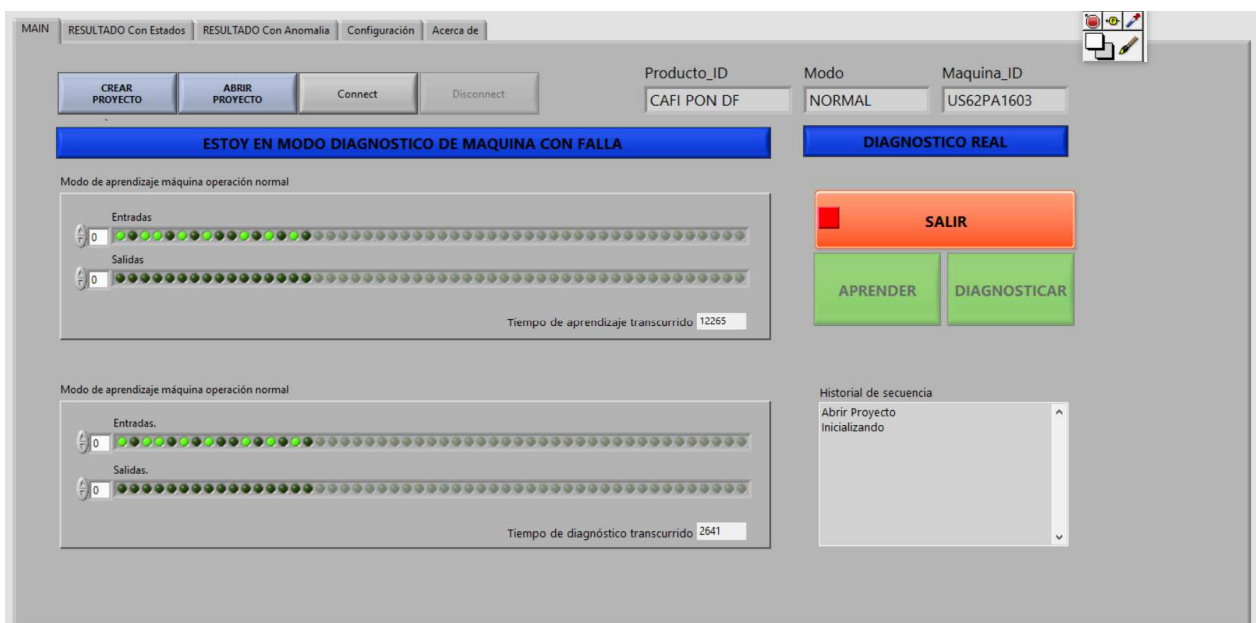


Figura 24. Analizador universal de fallos de PLC, pantalla principal en configuración para 16 entradas.

Fuente: Elaboración propia.

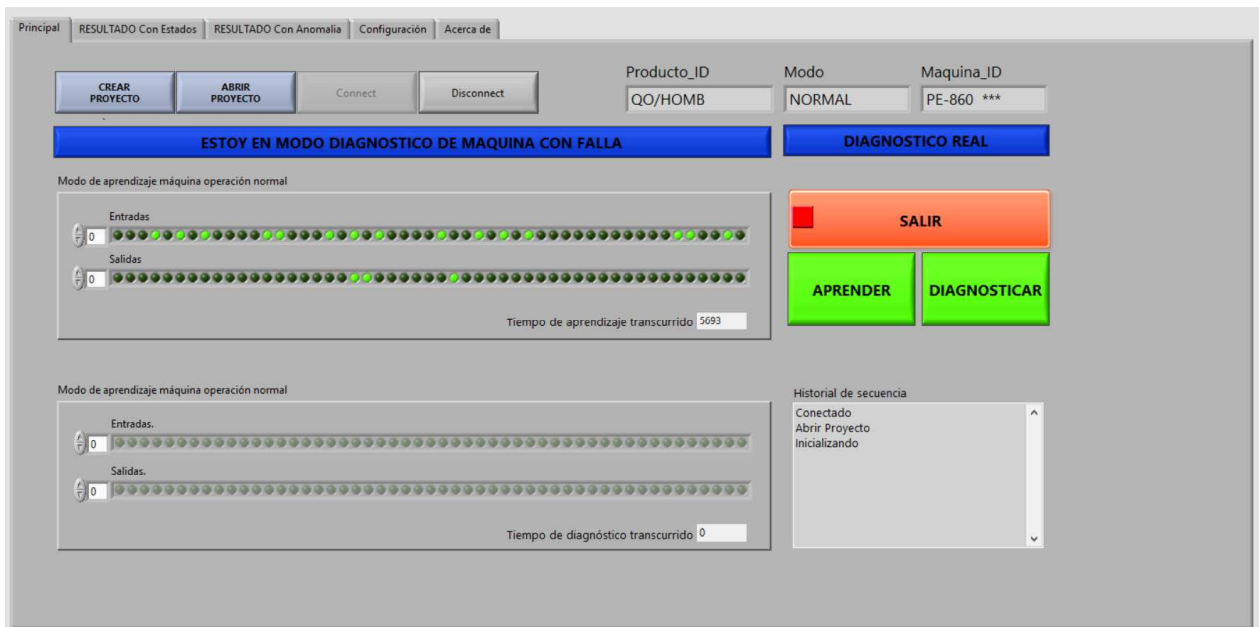


Figura 25. Analizador universal de fallos de PLC, pantalla en proceso de aprendizaje-entrenamiento en máquina con 64 entradas Fuente: Elaboración propia.

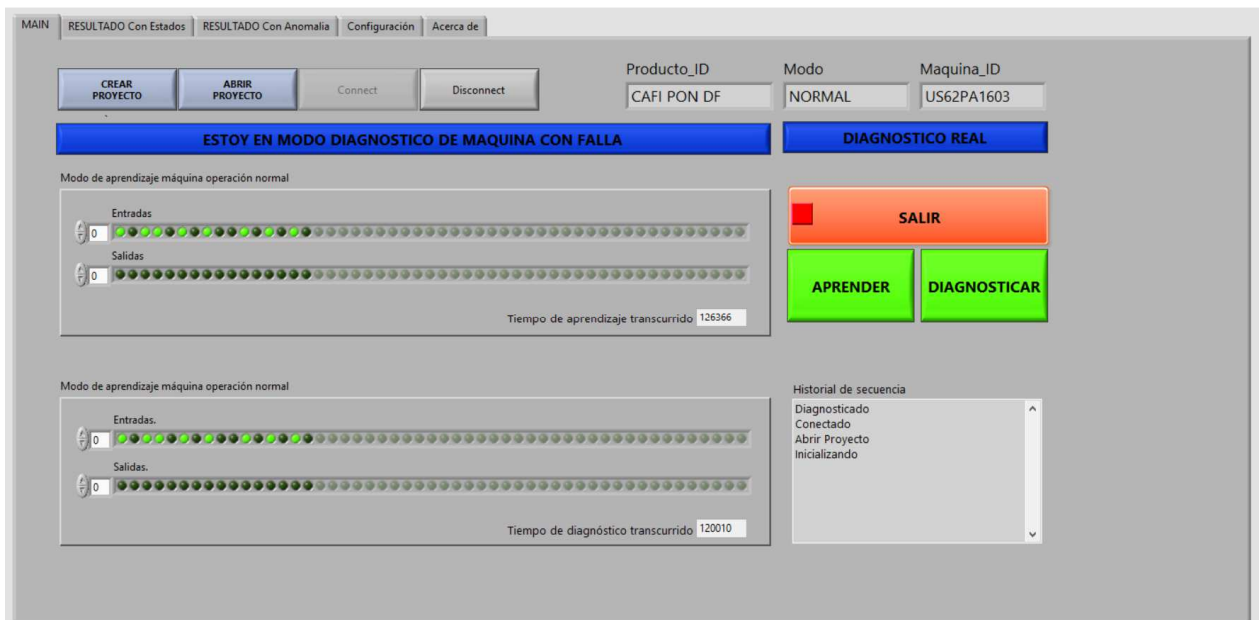


Figura 26. Analizador universal de fallos de PLC, pantalla en proceso de diagnóstico Fuente: Elaboración propia.

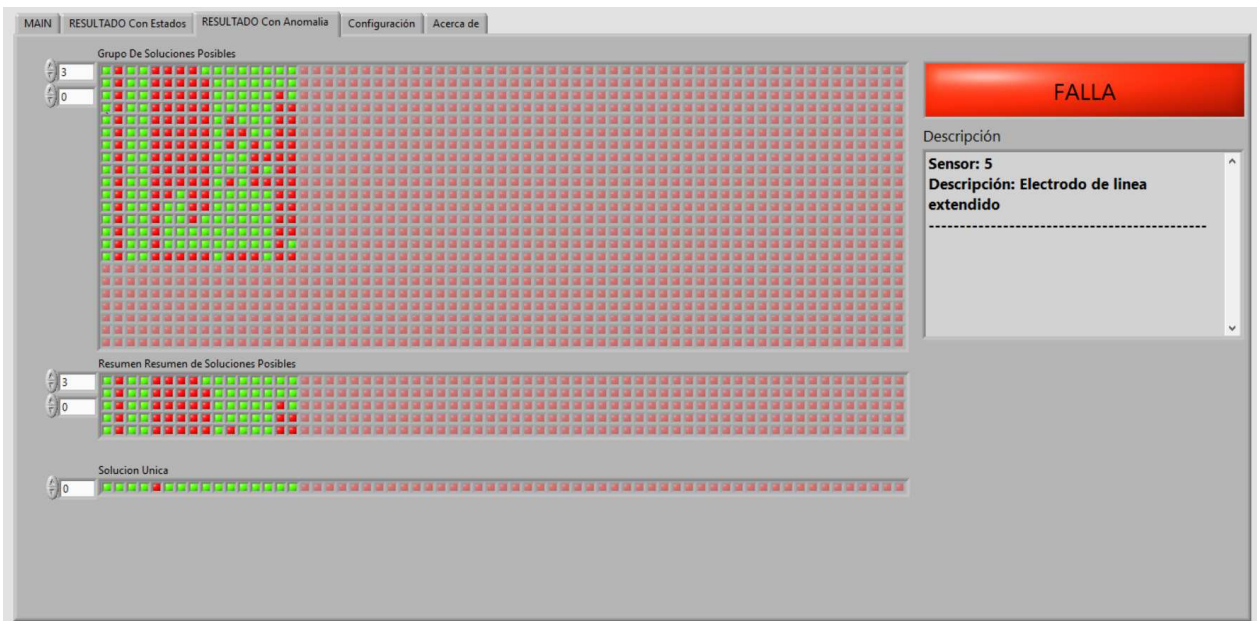


Figura 27. Analizador universal de fallos de PLC, pantalla con diagnóstico concluido informando la causa de la falla en máquina de simple de 16 entradas, estados consecutivos. Fuente: Elaboración propia.

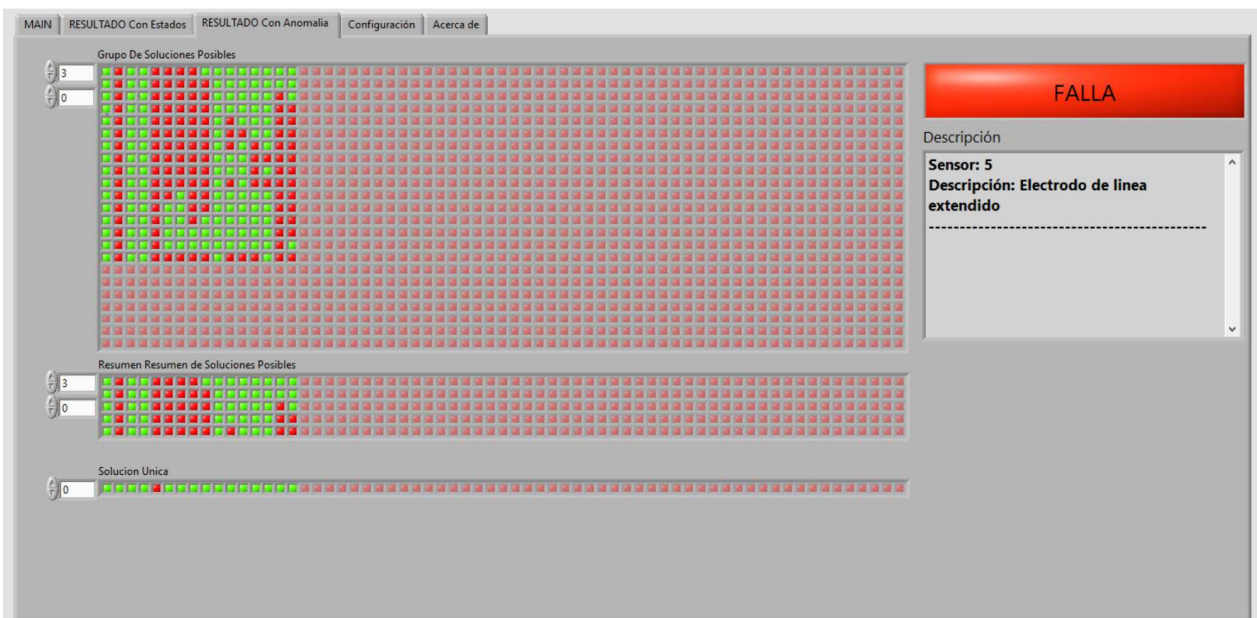


Figura 28. Analizador universal de fallos de PLC, pantalla con diagnóstico concluido informando la causa de la falla en máquina de compleja de 64 entradas, en máquina compleja con múltiples operaciones simultaneas. Fuente: Elaboración propia.

Principal | RESULTADO Con Estados | RESULTADO Con Anomalia | Configuración | Acerca de

Configuración del Modelo 2

Configuration File

PLC Slave Address	Port	PLC_Name	Machine Name
<input type="text" value="157.198.219.106"/>	<input type="text" value="502"/>	<input type="text" value="XYZ"/>	<input type="text" value="Analoga"/>

Cell Name	PLC_ID	Machine_ID	Product_ID
<input type="text" value="CELULA 1"/>	<input type="text" value="ABCD"/>	<input type="text" value="PE-860 *** INPUT 13"/>	<input type="text" value="QO/HOMB"/>

Modo: Reservado:

Tiempo de aprendizaje (seg): Tiempo de diagnóstico (seg):

Cantidad de entradas digitales: Cantidad de salidas digitales:

ReadFiles error
 status: code:
 source:

Mod Bus Diagnosticar Error
 status: code:
 source:

Mod Bus Aprender Error
 status: code:
 source:

Figura 29. Analizador universal de fallos de PLC, pantalla de configuración. Fuente: Elaboración propia.

Principal | RESULTADO Con Estados | RESULTADO Con Anomalia | Configuración | Acerca de

Analizador universal de fallos de PLC
 para identificación de causa raíz de paro de máquina

Autor:
 Manuel Antonio Ruiz Ochoa

Tijuana B.C., México
 Marzo 2020

Figura 30. Analizador universal de fallos de PLC, pantalla "Acerca de", Manuel Antonio Ruiz Ochoa. Fuente: Elaboración propia.

5.2 Validar la confiabilidad.

Al utilizar la estación Calibrador PA-1603, Sorteador TP-004 y Análoga PE-791 para cubrir los tres tipos de máquina indicados en la Figura 28, fue provocada la falla para cada una de las entradas de sensor posibles del equipo y aplicado el analizador universal de fallos de PLC fue validada la certeza en la detección de la fuente de falla y también verificando la no detección de fallas al encontrarse en operación normal, obteniéndose los resultados mostrados en las tablas 5, 6 y 7.

Tabla 5. Tabla de aceptación en la detección de fallas conocidas, al desconectar cada señal de PLC, en calibrador PA-1603. Fuente: Elaboración propia.

Sensor	Descripción	Diagnóstico automatizado (minutos)	Detectado	Comentarios
1	Presencia de 24 VDC	2.16	SI	
2	Puerta de seguridad	2.16	SI	
3	Presencia de Interruptor	2.16	SI	
4	Electrodo de línea retraído	2.16	SI	
5	Electrodo de línea extendido	2.16	SI	
6	Electrodo de carga retraído	2.16	SI	
7	Electrodo de carga extendido	2.16	SI	
8	Electrodo de carga totalmente extendido	2.16	SI	
9	Re-enganche de reseteo retraído	2.16	SI	
10	Re-enganche de reseteo extendido	2.16	SI	
11	Re-enganche encendido retraído	2.16	SI	
12	Re-enganche encendido extendido	2.16	SI	
13	Respaldo	NA	NA	
14	Respaldo	NA	NA	
15	Presencia de Aire	2.16	SI	
16	No conexión	NA	NA	
No Falla	Todas las señales conectadas correctamente	2.16	SI	Reportado como buena

Media 2.16 min.
Confiabilidad 100%

Tabla 6. Tabla de aceptación en la detección de fallas conocidas, al desconectar cada señal de PLC, en máquina sorteador TP-004. Fuente: Elaboración propia.

Sensor	Descripción	Diagnóstico automatizado (minutos)	Detectado	Comentarios
1	Presencia de 24 VDC	2.08	SI	
2	Puerta de seguridad	2.08	SI	
3	Presencia de Interruptor	2.08	SI	
4	Electrodo de línea Retraído	2.08	SI	
5	Electrodo de línea extendido	2.08	SI	
6	Electrodo de carga retraído	2.08	SI	
7	Electrodo de carga extendido	2.08	SI	
8	Electrodo de carga totalmente extendido	2.08	SI	
9	Latch de reseteo retraído	2.08	SI	
10	Latch de reseteo extendido	2.08	NO	No detectado
11	Latch On retraído	2.08	SI	
12	Latch On extendido	2.08	SI	
13	Respaldo	NA	NA	
14	Respaldo	NA	NA	
15	Presencia de Aire	2.08	SI	
16	Inicio de prueba	2.08	SI	
No Falla	Todas las señales conectadas correctamente	2.08	SI	Reportado como buena

Media 2.16 min.
 Confiabilidad 93.33%

Tabla 7. Tabla de aceptación en la detección de falla conocida, al desconectar cada señal de PLC, en máquina análoga PE-791. Fuente: Elaboración propia.

Sensor	Descripción	Diagnóstico automatizado (minutos)	Detectado	Comentarios
1	Alimentador de entrada abajo	4.16	SI	
2	Interruptor de calibración en nido	4.16	SI	
3	Elevador del calibrador arriba	3.33	SI	
4	Elevador del calibrador abajo	3.33	SI	
5	Electrodos del calibrador extendidos	3.33	SI	
6	Electrodos del calibrador retraídos	3.33	SI	
7	Quijada del electrodo de calibración extendido	3.16	SI	
8	Quijada del electrodo de calibración retraído	3.16	SI	
9	Interruptor en calibración enganchado	3.16	SI	
10	Interruptor en calibración encendido	3.16	SI	
11	Reserva			
12	Eyector del Interruptor de calibración extendido	3.33	SI	
13	Eyector del Interruptor de calibración retraído	3.33	SI	
14	Riel de alimentador de entrada al sorteador lleno			
15	Riel de alimentador de entrada al sorteador iniciado			
16	Interruptor de sorter en nido			
17	Elevador de sorter arriba	5.25	SI	
18	Elevador de sorter abajo			
19	Electrodos de sorter extendidos	5.25	Parcial	3 soluciones sugeridas
20	Electrodos de sorter retraídos	5.25	SI	
21	Quijada del electrodo de sorter extendido			
22	Quijada del electrodo de sorter retraído			
23	Interruptor de sorter enganchado	4.16	SI	
24	Interruptor de sorter encendido			
25	Corriente de sorter detectada			
26	Actuador de de Interruptor de sorter extendido			
27	Actuador del Interruptor de sorter retraído	5.25	SI	
28	Interruptor en contenedor de rechazo detenido	5.25	SI	
29	Compuerta de rechazo retraída			
30	Compuerta de rechazo extendida	5.25	SI	
31	Actuador de rechazo extendido	5.25	SI	
32	Actuador de rechazo retraído	4.16	SI	
33	Paro de rechazo abajo	3.33	SI	
34	Ciclo encendido	3.33	SI	
35	Ciclo iniciado	3.33	En Estudio	No detectado
36	Resetear calibración			
37	Resetear sorter			
38	Corriente magnética sensada			
39	Reserva			
40	Reserva			
41	Reserva			
42	Reserva			
43	Reserva			
44	Reserva			
45	Reserva			
46	Riel de salida en calibrador elevado	3.16	SI	
47	Riel de salida en sorter elevado	5.25	SI	
48	Llave del bypass de seguridad	3.16	SI	
49	Sensor de bloqueo de compuerta de rechazo	5.25	SI	
50	Monitor de 24VDC	3.16	SI	
51	Sensor del riel de alimentación a sorter	3.16	SI	
52	Contactador del sorter de prueba magnética	5.25	SI	
53	Contactador del sorter de prueba térmica	5.25	SI	
54	Prueba Magnética encendido/apagado	5.25	SI	
55	Presión de aire correcta	3.16	SI	
56	Diagnóstico en operación normal de máquina buena	5.25	SI	Reportado como buena

Media 4.09 min.
Exactitud 94.28%

5.3 Prueba preliminar, verificar reducción en tiempo de diagnóstico.

Al utilizar la estación Calibrador PA-1603 mencionado en la tabla 8, fue provocada la falla en cuatro señales de sensores, la existencia de la falla específica era desconocida por el técnico quien la diagnosticó y luego fue medido su tiempo invertido para encontrar la falla y comparó con el tiempo de diagnóstico de este nuevo sistema para exactamente esa misma falla, obteniéndose los datos mostrados en la tabla 8 y representados en figuras 32 y 33. En esta prueba preliminar y rápida la reducción en tiempo fue de 38.25 minutos, representando un mejoramiento del 94.42%, a partir de este resultado fue iniciado un análisis estadístico más detallado.

Tabla 8. Tabla de resultados de la prueba preliminar para verificar mejoramiento en tiempos de diagnóstico del método humano contra este nuevo sistema de diagnóstico automatizado. Fuente: Elaboración propia.

Tipo de Falla	Descripción	Diagnóstico humano (minutos)	Diagnóstico automatizado (minutos)	Diferencia (minutos)	Mejora (%)	Detectado
Sensor de Entrada 1	Presencia de 24 VDC	44	2.25	41.75	94.89%	SI
Sensor de Entrada 6	Electrodo de carga retraido	37	2.25	34.75	93.92%	SI
Sensor de Entrada 7	Electrodo de carga extendido	39	2.25	36.75	94.23%	SI
Sensor de Entrada 11	Latch On retraido	42	2.25	39.75	94.64%	SI

Media 40.5 2.25 38.25 94.42%

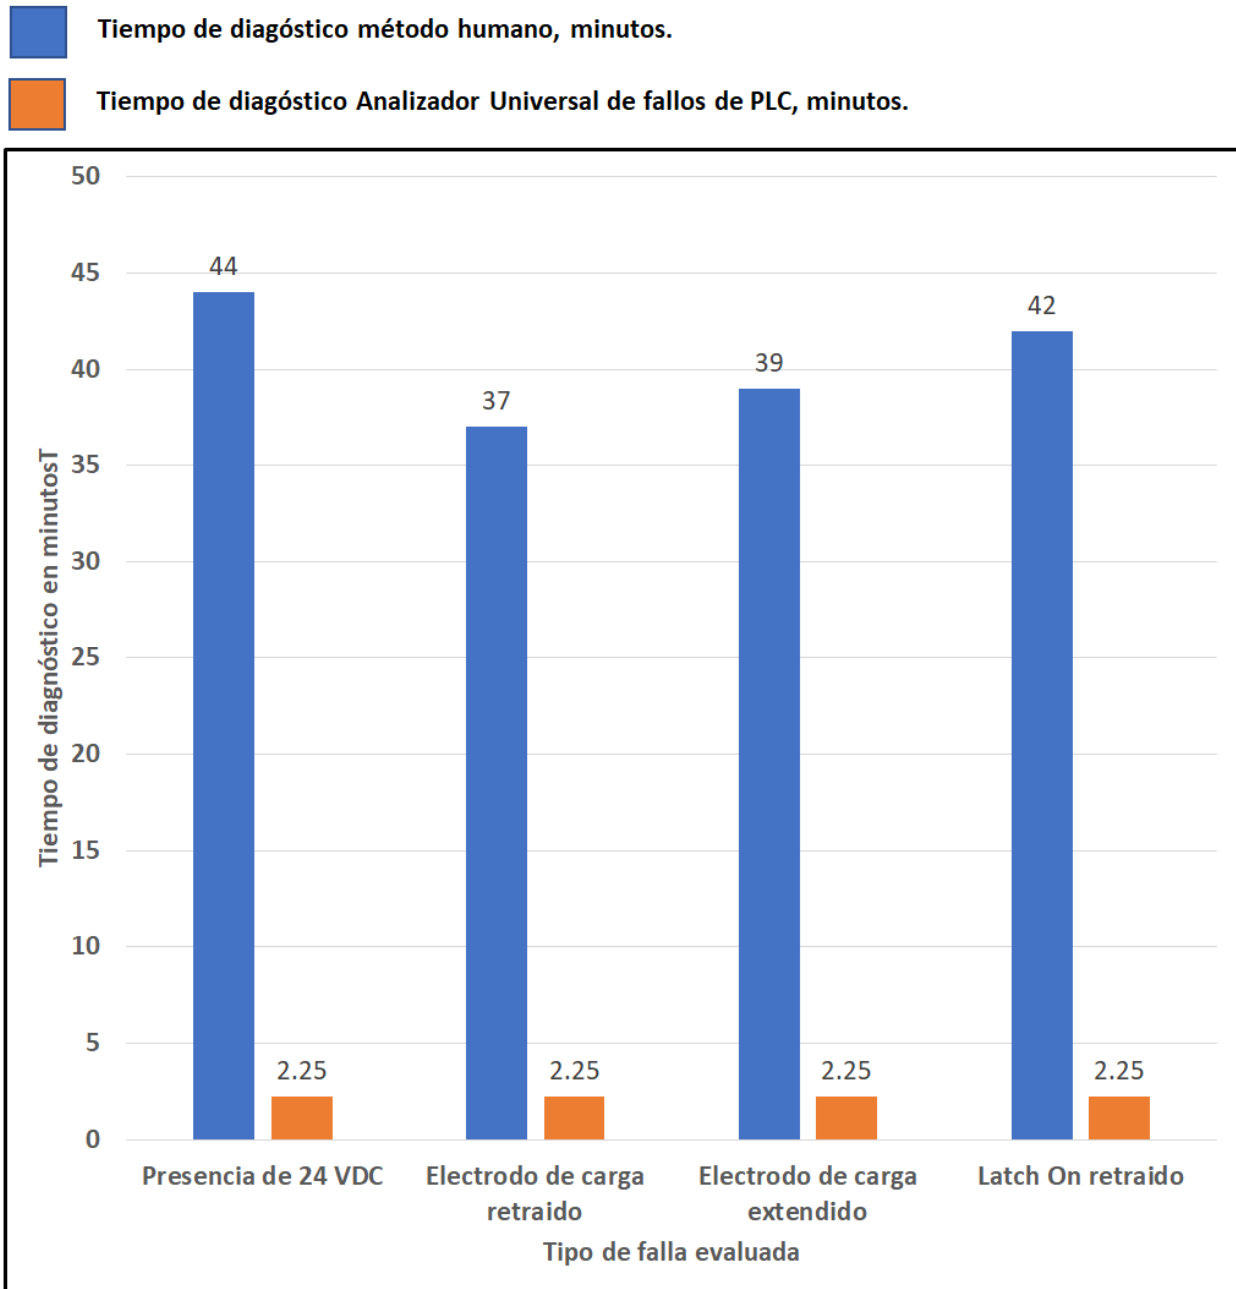


Figura 31. Gráfica de resultados indicando la diferencia en minutos, de la prueba de mejoramientos en tiempos de diagnóstico del sistema humano contra el Analizador Universal de Fallos de PLC. Fuente: Elaboración propia.

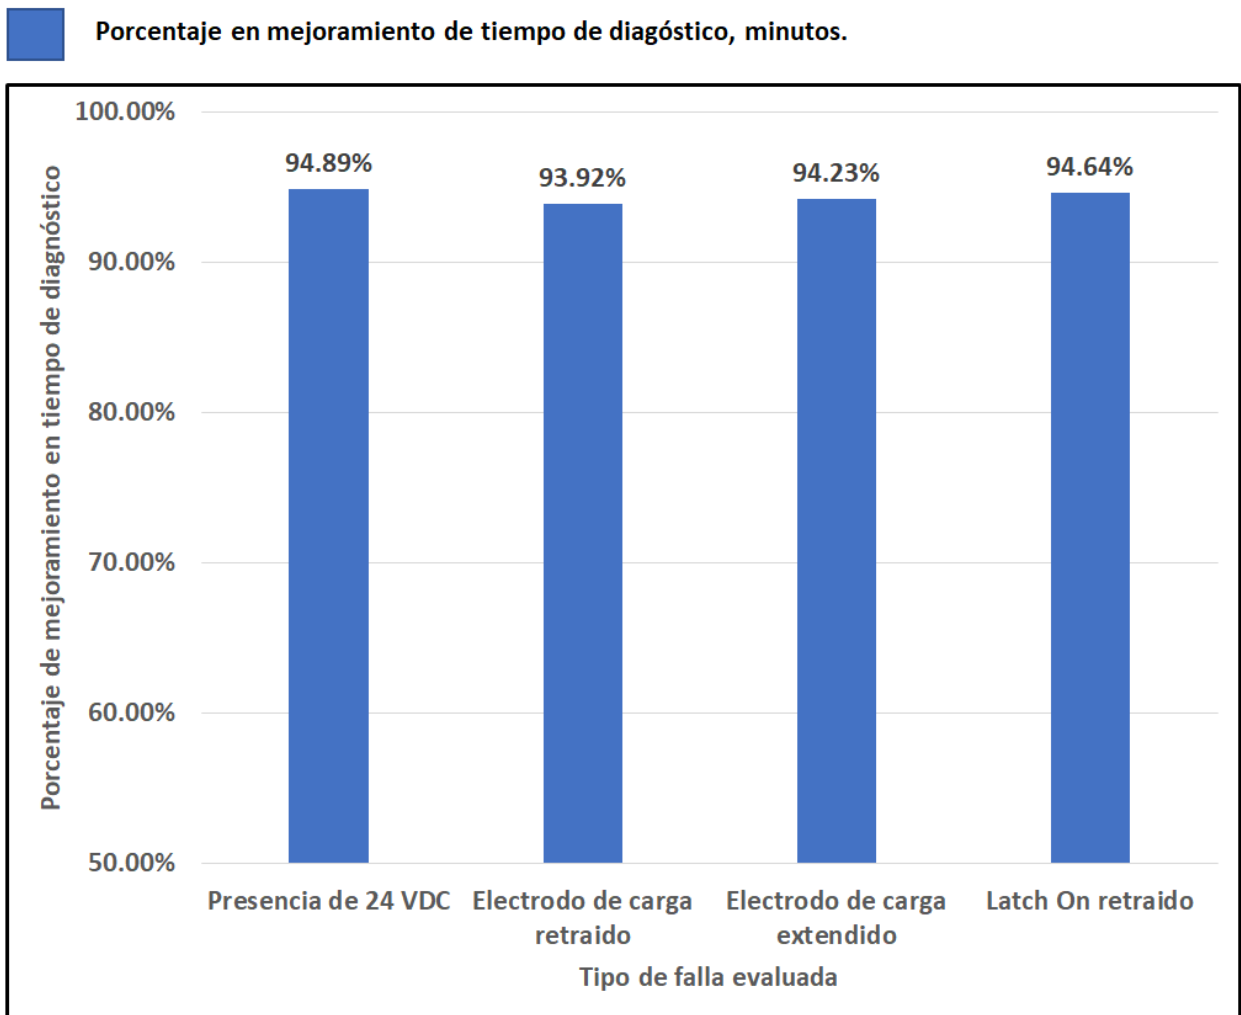


Figura 32. Gráfica de resultados indicando el porcentaje de mejoramiento del Analizador Universal de fallos de PLC contra el método humano. Fuente: Elaboración propia.

5.4 Medición en condiciones reales de fallas en campo.

Fue solicitado el apoyo del departamento de mantenimiento para informar el momento de una falla en el equipo. Para las mediciones en pruebas de campo los resultados son representados en la tabla 9 con sus respectivos tiempos de diagnóstico al utilizar el programa Analizador Universal de Fallos de PLC.

Tabla 9. Tabla de tiempos de diagnóstico para recuperación de equipo caído de casos reales en producción en el periodo de un mes utilizando el programa Analizador Universal de Fallos de PLC. Fuente: Elaboración propia.

Fecha	Máquina	Tipo	Falla	Fuente de falla (señal del PLC)	Familia de Falla	Tiempo (minutos)	Detectado	Comentario
1 30/1/2020	PA-1603	Calibrador	Inicia la prueba pero se detiene	Electrodo de carga extendido	Ajuste de sensor	2.25	SI	
2 31/1/2020	TP-004	Sorteador	No inicia la prueba	Re-enganche de reseteo retraído	Ajuste de sensor	2.08	SI	
3 3/2/2020	PE-860	Análoga	Se coloca el breaker, lo detecta pero no inicia	Electrodos del calibrador extendidos	Ajuste de sensor	3.16	SI	
4 4/2/2020	PE-729	Análoga	No inicia la prueba	Interruptor en calibración enganchado	Ajuste de sensor	3.16	SI	
5 5/2/2020	PA-1603	Calibrador	No inicia la prueba	Electrodo de línea retraído	Ajuste de sensor	1.41	SI	
6 5/2/2020	PA-1602	Calibrador	Inicia la prueba pero se detiene	Re-enganche de reseteo extendido	Cambio de sensor	2.35	SI	
7 5/2/2020	PE-836	Análoga	No inicia la prueba	Elevador del calibrador arriba	Ajuste de sensor	3.33	SI	
8 7/2/2020	TP-005	Sorteador	No inicia la prueba	Electrodo de carga retraído	Ajuste de sensor	1.33	SI	
9 7/2/2020	TP-004	Sorteador	No inicia la prueba	Re-enganche encendido extendido	Ajuste de cilindro	2.08	SI	
10 7/2/2020	PE-791	Análoga	No inicia prueba de sorter	Electrodo de línea de sorter extendido	Ajuste de sensor	3.16	SI	
11 7/2/2020	BC1404-03	Calibrador	No inicia la prueba	Presencia de Aire	Cambio de electro válvula	3.33	SI	
12 11/2/2020	PA-1603	Calibrador	Avanza y se detiene antes de calibrar	Electrodo de carga extendido	Ajuste de sensor	1.41	SI	
13 11/2/2020	TP-004	Sorteador	Inicia pero se detiene al empezar la prueba	Re-enganche de reseteo retraído	Ajuste de sensor	2.08	SI	
14 12/2/2020	PE-729	Análoga	No inicia calibración	Compuerta de rechazo abajo	Cambio de Fibra	3.33	SI	
15 12/2/2020	PE-836	Análoga	No inicia calibración	Electrodos del calibrador retraídos	Ajuste de sensor	3.33	SI	
16 13/2/2020	PE-860	Análoga	No sale del nido de calibración	Interruptor en calibración enganchado	Ajuste de sensor	3.33	SI	
17 17/2/2020	PA-1501	Calibrador	No inicia la prueba	Re-enganche encendido extendido	Ajuste de sensor	1.41	SI	
18 17/2/2020	CA-4238	Análoga	No avanza a sorter	Elevador de sorter arriba	Ajuste de sensor	5.25	SI	
19 18/2/2020	PE-860	Análoga	No termina la prueba de sorter	Eyector del Interruptor de sorter retraído	Ajuste de sensor	5.25	SI	
20 18/2/2020	PE-836	Análoga	No avanza a sorter	Actuador de rechazo extendido	Cambio de cable de sensor	5.25	SI	
21 18/2/2020	T-006	Sorteador	Avanza pero se bloquea	Electrodo de carga extendido	Ajuste de sensor	2.35	SI	
22 19/2/2020	CA4238	Análoga	No avanza a sorter	Electrodos de sorter extendidos	Ajuste de cilindro	4.16	SI	3 opciones sugeridas
23 19/2/2020	CA-353	Análoga	No rechaza en sorter	Sensor de bloqueo de compuerta de rechazo	Ajuste de sensor	5.25	SI	
24 19/2/2020	T-006	Sorteador	Interruptor atorado	Electrodo de carga retraído	Ajuste de sensor	2.35	SI	
25 20/2/2020	PE-850	Análoga	No inicia prueba de sorter	Sensor del riel de alimentación a sorter	Ajuste de sensor	5.25	SI	
26 20/2/2020	CA-4311	Análoga	No abre puerta de rechazo	Actuador de rechazo extendido	Ajuste de sensor	4.16	SI	
27 21/2/2020	BC1404-03	Calibrador	No sale del nido de calibración	Electrodo de línea extendido	Cambio de sensor	2.35	SI	
28 24/2/2020	TP-004	Sorteador	No inicia la prueba	Re-enganche de reseteo retraído	Ajuste de sensor	1.41	SI	
29 24/2/2020	CA-4238	Análoga	Inicia la prueba pero se detiene en sorter	Compuerta de rechazo retraída	Cambio de sensor	4.16	SI	
30 25/2/2020	BC1404-08	Sorteador	No inicia la prueba	Latch de reseteo extendido	Ajuste de sensor	5.16	NO	
31 26/2/2020	PE-860	Análoga	Se detiene en sorter	Elevador de sorter arriba	Ajuste de sensor	5.25	SI	
32 27/2/2020	CA-353	Análoga	No avanza a calibración	Interruptor en nido de calibración, no liberado	Ajuste de sensor	2.16	SI	
33 27/2/2020	PA-1602	Calibrador	Se detiene al enganchar	Electrodo de línea retraído	Ajuste de sensor	1.33	SI	
34 28/2/2020	CA-4311	Análoga	No engancha electrodo	Actuador de interruptor de calibración retraído	Ajuste de sensor	2.08	SI	
35 28/2/2020	TP-005	Sorteador	No inicia la prueba al cerrar puerta	Presencia del interruptor	Reemplazo de Interlock	3.16	SI	
36 3/3/2020	CA-353	Análoga	No inicia en calibración	Electrodos del calibrador retraídos	Ajuste de sensor	3.33	SI	
37								
38								
39								

Promedio 3.12 min.

Máximo 5.25 min.

Mínimo 1.33 min.

5.5 Prueba de hipótesis.

μ_A : Media de método de diagnóstico automatizado utilizando el Analizador Universal de Fallos de PLC.

μ_H : Media de método de diagnóstico Humano.

La hipótesis estadística fue planteada de la siguiente manera:

$$H_0: \mu_A \geq \mu_H$$

$$H_a: \mu_A < \mu_H$$

Utilizando prueba t parada:

\bar{d} : Media de las diferencias de las dos muestras.

Sd : Desviación estándar de las diferencias de las dos muestras.

Z: Puntuación Z para el nivel de confianza del 95%, 1.96.

α : Error de la muestra, 5%.

$t_{\frac{\alpha}{2}}$: Valor en tabla t student para $\frac{\alpha}{2} = 0.025$, 9 grados de libertad, 2.262

n : Tamaño de la muestra, 35 pares de tiempos, automatizado contra Humano, por concepto de "Falla de Sensor".

$$t = \frac{\bar{d}}{sd/\sqrt{n}} \text{ (Walpole, 2012)}$$

Como resultado, el procedimiento de prueba consiste en no rechazar **H0** cuando

$$-z\alpha/2 < t < z\alpha/2 \text{ (Walpole, 2012)}$$

El intervalo de confianza es calculado con la fórmula:

$$\bar{d} \pm t_{\frac{\alpha}{2}} * \frac{Sd}{\sqrt{n}} \text{ (Walpole, 2012)}$$

Los datos recolectados para la prueba t pareada son mostrados en la tabla 10, consisten en el tiempo de diagnóstico automatizado comparado con el tiempo de diagnóstico humano para el mismo tipo de máquina, además en la última columna es calculado el porcentaje de mejoramiento de la diferencia del par con el propósito de posteriormente calcular también el porcentaje de mejoramiento efectivo del nuevo sistema.

Tabla 10. Tabla en pares de tiempos de diagnóstico, a la izquierda utilizando diagnóstico humano, a la derecha diagnóstico automatizado, para muestras dependientes, máquinas iguales con misma familia de falla. Fuente: Elaboración propia.

Diagnóstico Automatizado				Diagnóstico Humano				% de reducción	
Máquina	Tipo	Familia de Falla	Tiempo (minutos)	Máquina	Tipo	Familia de Falla	Tiempo (minutos)		
1	PA-1603	Calibrador	Ajuste de sensor	2.25	PA-1603	Calibrador	Ajuste de sensor	33.60	93.3%
2	TP-004	Sorteador	Ajuste de sensor	2.08	TP-004	Sorteador	Ajuste de sensor	31.68	93.4%
3	PE-860	Análoga	Ajuste de sensor	3.16	PE-860	Análoga	Ajuste de sensor	32.16	90.2%
4	PE-729	Análoga	Ajuste de sensor	3.16	PE-729	Análoga	Ajuste de sensor	21.60	85.4%
5	PA-1603	Calibrador	Ajuste de sensor	1.41	PA-1603	Calibrador	Ajuste de sensor	38.00	96.3%
6	PA--1602	Calibrador	Cambio de sensor	2.35	PE-849	Calibrador	Ajuste de sensor	13.20	82.2%
7	PE-836	Análoga	Ajuste de sensor	3.33	PE-836	Análoga	Ajuste de sensor	24.00	86.1%
8	TP-005	Sorteador	Ajuste de sensor	1.33	PE-775	Sorteador	Ajuste de sensor	12.28	89.2%
9	TP-004	Sorteador	Ajuste de cilindro	2.08	PE-620	Sorteador	Ajuste de cilindro	15.84	86.9%
10	PE-791	Análoga	Ajuste de sensor	3.16	PA-202	Análoga	Cambio de sensor	48.00	93.4%
11	BC1404-03	Calibrador	Ajuste de sensor	3.33	BC1404-03	Calibrador	Ajuste de sensor	37.44	91.1%
12	PA-1603	Calibrador	Ajuste de sensor	1.41	PA-1603	Calibrador	Ajuste de sensor	32.16	95.6%
13	TP-004	Sorteador	Ajuste de sensor	2.08	PE-620	Sorteador	Ajuste de sensor	30.30	93.1%
14	PE-729	Análoga	Cambio de Fibra	3.33	PE-729	Análoga	Cambio de sensor	21.60	84.6%
15	PE-836	Análoga	Ajuste de sensor	3.33	BC1709	Análoga	Ajuste de sensor	24.00	86.1%
16	PE-860	Análoga	Ajuste de sensor	3.33	PE-860	Análoga	Ajuste de sensor	32.16	89.6%
17	PA-1501	Calibrador	Ajuste de sensor	1.41	PA-1501	Calibrador	Ajuste de sensor	36.00	96.1%
18	CA-4238	Análoga	Ajuste de sensor	5.25	PA-1604	Análoga	Ajuste de sensor	18.24	71.2%
19	PE-860	Análoga	Ajuste de sensor	5.25	PE-860	Análoga	Ajuste de sensor	16.80	68.8%
20	PE-836	Análoga	Cambio de cable de sensor	5.25	PA-232	Análoga	Cambio de sensor	24.00	78.1%
21	T-006	Sorteador	Ajuste de sensor	2.35	PB-0047	Sorteador	Ajuste de sensor	22.30	89.5%
22	CA4238	Análoga	Ajuste de cilindro	4.16	CA4039	Análoga	Ajuste de cilindro	24.00	82.7%
23	CA-353	Análoga	Ajuste de sensor	5.25	CA-353	Análoga	Cambio de sensor	45.00	88.3%
24	T-006	Sorteador	Ajuste de sensor	2.35	CA-5492	Sorteador	Ajuste de sensor	21.20	88.9%
25	PE-850	Análoga	Ajuste de sensor	5.25	PE-850	Análoga	Cambio de sensor	31.20	83.2%
26	CA-4311	Análoga	Ajuste de sensor	4.16	CA-1894	Análoga	Ajuste de sensor	24.00	82.7%
27	BC1404-03	Calibrador	Cambio de sensor	2.35	BC1404-21	Calibrador	Cambio de sensor	15.89	85.2%
28	TP-004	Sorteador	Ajuste de sensor	1.41	TP-004	Sorteador	Ajuste de sensor	24.00	94.1%
29	CA-4238	Análoga	Cambio de sensor	4.16	CA-5201	Análoga	Cambio de sensor	15.80	73.7%
30	CA-353	Análoga	Ajuste de sensor	3.33	PE-782	Análoga	Ajuste de sensor	12.28	72.9%
31	PE-860	Análoga	Ajuste de sensor	5.25	PE-860	Análoga	Ajuste de sensor	16.80	68.8%
32	CA-353	Análoga	Ajuste de sensor	2.16	PE-464	Análoga	Ajuste de sensor	12.28	82.4%
33	PA-1602	Calibrador	Ajuste de sensor	1.33	BC1520-01	Calibrador	Ajuste de sensor	23.30	94.3%
34	CA-4311	Análoga	Ajuste de sensor	2.08	CA-4311	Análoga	Ajuste de sensor	24.00	91.3%
35	TP-005	Sorteador	Reemplazo de Interlock	3.16	BC1520-16	Sorteador	Reemplazo de Interlock	51.00	93.8%
36	CA-353	Análoga	Ajuste de sensor	3.33	PE-887	Análoga	Ajuste de sensor	31.68	89.5%

Al aplicar una representación gráfica con Minitab, para los porcentajes de mejoras en tiempos de diagnóstico observados en la tabla 10 y fueron obtenidos los resultados indicados en la figura 33.

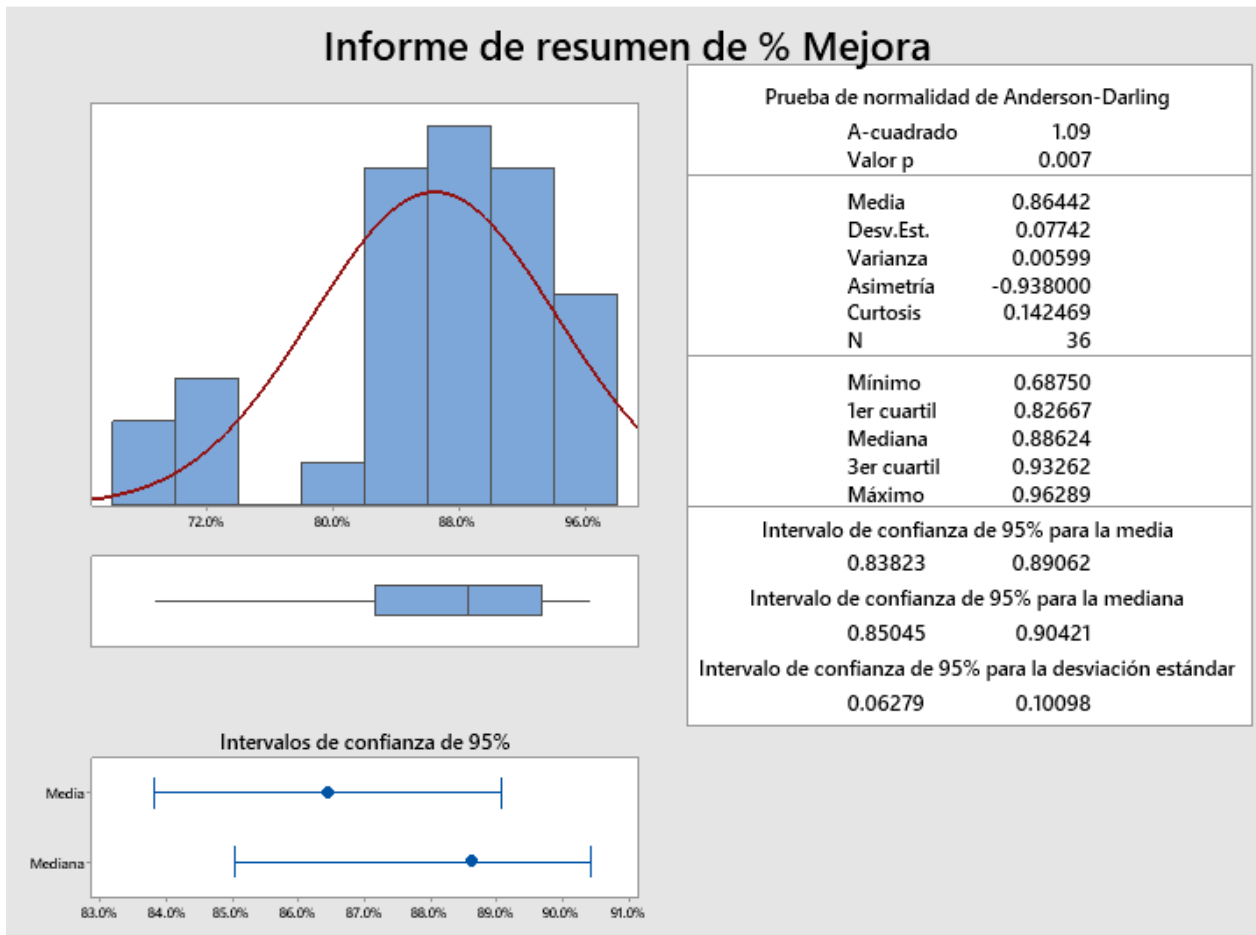


Figura 33. Representación gráfica del análisis estadístico de porcentaje de reducción en tiempo de diagnóstico. Fuente: Elaboración propia.

Los resultados de este análisis estadístico muestran los valores de porcentaje de mejora en tiempos de diagnóstico del sistema automatizado contra el tradicional humano, indican una media de 86.44% con un intervalo de 83.82% a 89.06% a un nivel de confianza del 95%. Estos valores son superiores a la meta del 30% de reducción establecido en el objetivo general.

La representación gráfica también fue realizada para las diferencias de tiempos de los pares de la tabla 10 y fueron obtenidos los resultados representados en la figura 34.




Figura 34. Representación gráfica del análisis estadístico de pares de diferencias en tiempos de diagnóstico. Fuente: Elaboración propia.

Los resultados de este análisis estadístico muestran los valores de las diferencias en tiempos de diagnóstico del sistema automatizado contra el tradicional humano, indican una media de 22.98 con un intervalo de 19.568 minutos a 26.401 minutos con un nivel de confianza del 95%.

Para la comprobación de la hipótesis, fue aplicado el estadístico t pareada con Minitab para los pares de tiempos de diagnóstico presentados en tabla 10, los resultados son representados en figura 35.

IC y Prueba T pareada: Humano, Automático

Estadísticas descriptivas

Muestra	N	Media	Desv.Est.	Error estándar de la media
Humano	36	26.05	10.01	1.67
Automático	36	3.07	1.28	0.21

Estimación de la diferencia pareada

Media	Desv.Est.	Error estándar de la media	IC de 95% para la diferencia_μ
22.98	10.10	1.68	(19.57, 26.40)

diferencia_μ: media de (Humano - Automático)

Prueba

Valor T	Valor p
13.66	0.000

Figura 35. Resultado de prueba t pareada aplicada a los datos en tiempos de diagnóstico automatizado contra humano. Fuente: Elaboración propia.

El procedimiento de prueba con Minitab consiste en validar el estadístico Valor p para el rechazo de la hipótesis nula con la regla indicada en la tabla 11.

Tabla 11. Criterio para aceptación o rechazo de hipótesis nula utilizando el estadístico Valor p de la prueba t pareada. Fuente: Elaboración propia.

P-value < α	Ho	Rechazo de Hipótesis nula
	Ha	Aceptación de Hipótesis alternativa
P-value ≥ α	Ho	Fallo por aceptar Hipótesis nula
	Ha	Rechazo de Hipótesis alterna

Debido a un Valor p < 0.05, no pudo demostrarse la hipótesis nula **Ho** y por lo tanto fue asumida la hipótesis alternativa **Ha**.

Capítulo 7. Discusión de resultados

El estudio estadístico fue enfocado para evaluar la eficacia y velocidad de diagnóstico del programa desarrollado. Los dos parámetros utilizados para la evaluación del sistema fueron la confiabilidad para la detección de la fuente de falla y el estadístico de la prueba t pareada para la comprobación de la hipótesis. Los estudios realizados representados en las tablas 6 y 7 indicaron una confiabilidad del 94.28% para máquinas simples con estados secuenciales y un 93.33% para máquinas complejas realizando operaciones diversas en forma simultánea. Las fallas no detectadas por el sistema automatizado fueron porque el sistema arrojó más de una solución, aunque dentro de ese grupo existía la respuesta y otro caso en donde no fue detectada la fuente de falla porque la condición inicial para el diagnóstico del equipo caído no era la correcta porque un botón de reinicio, no incluido en la etapa de aprendizaje, fue presionado durante el proceso de diagnóstico, ocasionando conflicto al sistema no pudiendo ubicarlo dentro de los estados posibles. El análisis estadístico de mejoramiento de tiempo de diagnóstico, en figura 33, identificó una media de 86.44%, con un intervalo de confianza de 95%, del 83.82% a 89.06%. La prueba t pareada, mostrada en la figura 35, identificó una reducción en tiempo de diagnóstico con una media de 22.98 minutos, con una confianza de 95%, de 19.568 minutos a 26.401 minutos, y un Valor p de 0.000 para la prueba de hipótesis $H_0: \mu_A \geq \mu_H$, $H_a: \mu_A < \mu_H$ con $\alpha=0.05$ y debido a Valor $p < 0.05$, no pudo demostrarse la hipótesis nula H_0 y por lo tanto fue asumida la hipótesis alternativa H_a .

Al no demostrarse la hipótesis nula, fue asumido, el programa desarrollado redujo el tiempo de diagnóstico para fallas en sistemas industriales con PLC al utilizar una base de datos del estado de entradas con aprendizaje de máquina superando el objetivo de 30% de reducción.

Capítulo 8. Conclusiones

El programa desarrollado, con una base de datos de 42,114 registros de estado de máquina para 64 entradas con aprendizaje de máquina mediante una red neuronal de 4 capas redujo el tiempo de diagnóstico, de 26.42 minutos a 3.07 minutos, identificando una reducción, con una confianza del 95%, de 19.568 minutos a 26.401 minutos y un porcentaje de mejora del 83.82% a 89.06 del tiempo necesario para el diagnóstico en máquinas industriales basadas en PLC, para los dos tipos de máquinas evaluadas, el primer tipo, simple, donde los estados son secuenciales y para el segundo tipo, complejas, donde son ejecutadas secuencias diferentes de forma simultánea. Este porcentaje de mejoramiento es evidentemente más alto al 30% planteado en el objetivo. El programa sorprendentemente pudo diagnosticar fallas incluso sobre equipo donde los estados de máquina no son consecutivos y con operaciones simultáneas con una efectividad en la detección del 93.33%.

Es afirmando entonces, el nuevo programa redujo el tiempo de diagnóstico para fallas en sistemas industriales con PLC al utilizar una base de datos del estado de entradas con aprendizaje de máquina.

Como implementación futura es utilizar también las variables de entradas y salidas analógicas y memorias numéricas para poder diagnosticar fallas, no solo basadas en parámetros físicos sino también fallas basadas en valores de prueba fuera de especificación, siempre manteniendo el aprendizaje de máquina y sin programación adicional del PLC, además hay un amplio trabajo por realizar para tener una interfaz de usuario más amigable e intuitiva.

Lista de referencias bibliográficas

1. Acosta, R. J. (2008). Gestión de la calidad total. Madrid: Díaz de Santos.
2. Acosta, R. J. (2008). Seis Sigma un Enfoque Práctico. Madrid: Díaz de Santos.
3. Aquilino, R.P. (2007). Sistemas SCADA. Barcelona, España: Marcombo.
4. Benitez, R. (2008). Inteligencia Artificial Avanzada. Barcelona, España: UDC.
5. Antúñez, F. M. (2016). Puesta en marcha de sistemas de automatización industrial. Andalucía, España: IC Editorial.
6. Brambila, B. I. (1997). Manual para Elaboración de Tesis. México: Trillas.
7. Departamento de Manufactura SE (2020), Registros de tiempo Perdido 80-20. Schneider-Electric: Tijuana.
8. Enquist, M. (2008). Neural Network for Animal Behavior. New Jersey, U.S.A.: Princeton University Press
9. Fernando, M. C. (2018). Que es la Inteligencia Artificial. España: Bubok Publishing.
10. Graupe, D. (2013). Principles of Artificial Neural Networks. Illinois, Chicago: World Scientific.
11. Guzmán, F. A. (2014). Algebra Lineal. México: Editorial Patria.
12. Hernandez, C. O. (2014). Detección y Diagnóstico de fallas en sistemas eléctricos de potencia combinando lógica difusa, matrices y redes neuronales probabilísticas. COMIMSA.
13. Hernao, V. (2006). Neuroscheme. Colombia: Red Dyna.
14. Hines, W. W. (1996). Probabilidad y Estadística para Ingenieros y Administración. México: Continental.
15. Inteligencia Artificial. Métodos, Técnicas y Aplicaciones. (2008). España: McGraw-Hill.
16. Intervalos de Confianza para la diferencia de medias. (2014). Obtenido de Juárez, M. (2008).
17. Juárez, M. (2008). Inteligencia Artificial. Métodos, Técnicas y Aplicaciones. España: McGraw-Hill.
18. Lameda, C. (2015). Repid. Unexpo. Vrb: Métodos relacionados con diagnósticos de fallas con síntomas imprecisos mediante comparación de casos, Venezuela, 5(3), 850-862.

19. Matich, D. J. (2001). *Redes Neuronales Conceptos y Aplicaciones*. Rosario, Argentina: Universidad Politécnica.
20. Mira, J. (2008). *Aspectos conceptuales de la Inteligencia Artificial y la Ingeniería de Conocimiento*. España: McGraw-Hill.
21. Navidi, W. (2006). *Estadística para ingenieros*. Colorado: McGraw Hill.
22. Pascual, M. D. (2012). *Toyota: principios y fortalezas de un modelo de empresa*. Buenos Aires: Pluma Digital Ediciones.
23. Perez, R. (2012). *Una introducción al cómputo neural artificial*. Argentina: El Cid.
24. Perry, W. I. (1990). *Algebra lineal con aplicaciones*. México: Mc Graw Hill .
25. Pulido, H. G. (2010). *Calidad Total y Productividad*. México: Mc Graw-Hill.
26. Richard E. Woods, R. C. (1996). *Tratamiento digital de imágenes*. Wilmington: Addison-Wesley.
27. Sampieri, R. H. (1995). *Metodología de la Investigación*. México: Publi-Mex S.A.
28. Simon, L. M. (2011). *Fault Detection: Theory, Methods and Systems*. New York, U.S.A.: Nova Science.
29. Socconini, L. (2019). *Lean Manufacturing*. Barcelona: Marge Books.
30. Venkatasubramanian, V. R. (2003). A review of process fault detection and diagnosis Part III: Process history based métodos. Houston, TX: *Computes and Chemical Engineering*, 27-346.
31. Villegas, M. A. (2005). *Inferencia Estadística*.
32. Walpole, M. (2012). *Probabilidad y Estadística para Ingenieros y Ciencias*. México: Pearson.
33. Zaknich, A. (2010). *Neural Networks for Intelligent Signal Processing*. Australia: Word Scientific.